

Thèse

Pour obtenir le grade de docteur délivré par

École Doctorale GAIA

(Université de Montpellier - Montpellier SupAgro - AgroParisTech)

Spécialité : Écologie Fonctionnelle et Sciences Agronomiques

Suivi et modélisation des changements d'usage des terres et stocks de carbone dans les sols et les arbres dans le cadre de la REDD+ à Madagascar

Vers des mesures pertinentes localement et cohérentes à large échelle.

Présentée et soutenue publiquement par

Clovis Grinand

Le 16 décembre 2016

Devant le jury

Martial Bernoux, Co-directeur de thèse, Directeur de Recherche, IRD
Ghislain Vieilledent, Co-directeur de thèse, Chercheur, CIRAD (invité)
Frédéric Achard, Rapporteur, Directeur de Recherche, JRC
Richard Escadafal, Rapporteur, Directeur de Recherche, IRD
Valéry Gond, Examinateur, Chercheur, CIRAD
Philippe Lagacherie, Examinateur, Ingénieur de Recherche, INRA
Tantely Razafimbelo, Examinateur, Professeur, LRI
Matthieu Tiberghien, Directeur, Etc Terra (invité)

Remerciements

Le mémoire de thèse présenté dans les pages suivantes est le fruit de plusieurs années de réflexions, discussions et collaborations scientifiques, et il n'aurait pu voir le jour sans le concours de nombreuses personnes. Quelles soient ici toutes remerciées.

Ce projet de thèse est née avec et sous l'impulsion de Martial Bernoux à qui je dois mes premières expériences de « géographe-pédologue-modélisateur » bien avant le début de cette thèse. Martial m'a guidé vers le chemin de la thèse, malgré quelques réticences de ma part au début, puis fait confiance dans la conduite de ces travaux lorsque que je lui ai proposé ce projet. J'ai appris beaucoup à ses côtés, à la fois sur les exigences du travail scientifique, l'importance des collaborations, et bien sûr l'état des négociations internationales sur le climat, l'agriculture et la forêt. Je retiens aussi beaucoup de ses qualités humaines, mêlant modestie, convivialité et humour!

Je remercie chaleureusement Ghislain Vielledent avec qui j'ai également partagé des expériences scientifiques riches et structurantes en amont et pendant cette thèse. Sa rigueur et disponibilité à toute épreuve ont grandement contribué à l'aboutissement de ce travail. Son ouverture, curiosité et passion pour l'écologie ont été à l'origine de moult discussions inspirantes, tant au niveau de l'état de l'art des innovations technologiques que sur les grands enjeux de notre époque.

Je remercie particulièrement tous les membres du jury qui ont accepté d'évaluer mon travail, Frédéric Achard, Philippe Lagacherie, Richard Escadafal, Valéry Gond, pour leurs commentaires très pertinents et riches discussions que nous avons eus lors de la soutenance. Cette thèse s'est grandement enrichie grâce aux membres de mon comité de thèse pour leurs conseils avisés et leurs encouragements, notamment Gueric LeMaire et Raphaël Pelissier

Cette thèse n'aurait pu voir le jour sans la complicité et soutien de Tantely Razafimbelo et Herintsitohaina Razakamanarivo du Laboratoire des Radio-Isotopes à Antananarivo. Ce sont plusieurs années de partage et d'expériences variées avec Tantely et Narivo qui ont permis le bon déroulement et la concrétisation de cette thèse. Quelles soient ici profondément remerciées. Je ne saurais oublier de saluer l'ensemble des ingénieurs, doctorants et techniciens du LRI, avec qui j'ai partagé des bons moments lors de mes différents séjours à Madagascar, depuis 2007. Misaotra bestaka !

Cette thèse s'est nourri de l'expérience de chercheurs de l'IRD Eco&Sols qui m'ont fait découvrir leurs spécialités et avec qui j'ai eu de nombreuses discussions éclairantes. Merci à Lydie Lardy, Bernard Barthès, Raphaël Manlay, Alain Albrecht, Dominique Masse, et Jean

Luc Chotte. Je salue également l'ensemble de l'équipe d'Eco&Sols et en particulier Kenji Fusaki, Celine Ratier et Adoum Abdraman Abgassi qui m'ont été d'une grande aide et soutien lors de la dernière ligne droite.

Cette thèse n'aurait pu voir le jour sans l'engagement de l'Association EtcTerra et le soutien de Matthieu Tiberghien. Cette thèse, fruit d'une longue maturation, est née quasiment au même moment que qu'EtcTerra, association convaincue que Recherche et Développement doivent s'alimenter l'un l'autre. Mes expériences acquises en tant que chargé de projets R&D dans les différents projets d'EtcTerra, à Madagascar et ailleurs, ont grandement contribué à l'ouverture des ces recherches aux enjeux concrets des populations et l'opérationnalisation des outils et méthodes développées. Je voudrais ici remercier l'ensemble de l'équipe d'Etc Terra, mes collègues, avec qui nous partageons une belle aventure professionnelle et humaine!

Je voudrais aussi avoir une pensée particulière à mes quelques uns de mes « mentors » car – ils ne le savent surement pas – mais ils m'ont fait passer le virus de leur passion pour deux domaines scientifiques extraordinaires : la pédologie et la géographie. Je tiens à remercier particulièrement Claude Farrison de l'IUT Jean Monnet de Saint Etienne, Ary Bruand de l'Université d'Orléans et Dominique Arrouays, de l'Unité InfoSol de l'INRA d'Orléans. Mon parcours professionnel a été grandement influencé par mon passage à l'InfoSol, et notamment grâce à Dominique, qui m'a ouvert des opportunités et inspiré par ses qualités scientifiques et humaines.

Je ne peux oublier de mentionner ma famille, mes parents, mes grands-parents, mon frère et ma sœur qui m'ont accompagné tout au long de ce travail, en me « reboostant » dans les moments de doute et par leur présence tout simplement. Une tendre pensée à Aissatou qui m'a soutenu durant les derniers mois décisifs de travail, pour ses relectures et tout le reste; merci!

Sommaire

CHAPITRE 1 - INTRODUCTION GÉNÉRALE.....	10
1 CONTEXTE, DÉFINITIONS ET CADRE MÉTHODOLOGIQUE.....	11
2 PROBLÉMATIQUES SCIENTIFIQUES	22
3 OBJECTIFS ET PLAN DU MANUSCRIT	31
4 RÉFÉRENCES DU CHAPITRE 1	37
CHAPITRE 2 - SUIVI DE LA DÉFORESTATION EN RÉGION TROPICALE	42
1 CONTEXTE DE L'ÉTUDE.....	44
2 ESTIMATING DEFORESTATION IN TROPICAL HUMID AND DRY FORESTS IN MADAGASCAR FROM 2000 TO 2010 USING MULTI-DATE LANDSAT SATELLITE IMAGES AND THE RANDOM FORESTS CLASSIFIER.....	46
3 CONCLUSION DE L'ÉTUDE	76
4 REFERENCES DU CHAPITRE 2	77
CHAPITRE 3 – ESTIMATION DES STOCKS DE CARBONE DANS LE SOL	82
1 CONTEXTE DE L'ÉTUDE.....	84
2 ESTIMATING TEMPORAL CHANGES IN SOIL CARBON STOCKS AT ECOREGIONAL SCALE IN MADAGASCAR USING REMOTE-SENSING	86
3 CONCLUSION DE L'ÉTUDE	113
4 REFERENCES DU CHAPITRE 3	115
CHAPITRE 4 - MODÉLISATION DES CHANGEMENTS D'USAGE DES TERRES.....	122
1 CONTEXTE DE L'ÉTUDE.....	124
2 DEFORESTATION, LAND DEGRADATION AND REGENERATION MODELING USING MACHINE LEARNING TOOLS AND GLOBAL CHANGE DATASET: ASSESSMENT OF THE DRIVERS AND SCENARIOS OF LAND CHANGE IN MADAGASCAR	127
3 CONCLUSION DE L'ÉTUDE	151
4 REFERENCES DU CHAPITRE 4	153
CHAPITRE 5 – CONCLUSION GÉNÉRALE	160
1 SYNTHÈSE	162
2 DISCUSSION GÉNÉRALE ET PERSPECTIVES	166
3 CONCLUSION	186
4 RÉFÉRENCES DU CHAPITRE 5	187
LISTE DES COMMUNICATIONS	192
LISTE DES TABLEAUX	193
LISTE DES FIGURES.....	194
ANNEXES.....	197

Résumé

Le changement d'usage des terres, lié à l'agriculture et à la foresterie, engendre une perte importante de biodiversité et représente une part importante de nos émissions de gaz à effet de serres à l'origine du changement climatique. Le mécanisme de Réduction des Émissions liées à la Déforestation et à la Dégradation des forêts, conservation, gestion durable et restauration des stocks de carbone (REDD+) initié il y a dix ans peine à se mettre en place du fait de nombreuses contraintes politiques et scientifiques. Malgré l'existence de lignes directrices élaborées par la communauté scientifique internationale, des outils et données sont nécessaires afin de fournir des informations précises, à moindre coût et utilisables à différentes échelles. L'objectif de cette thèse est de développer des méthodologies innovantes pour réduire les incertitudes sur les estimations des émissions et séquestrations de CO₂ associées à la déforestation, dégradation et régénération des terres. Madagascar, pays engagé dans la REDD+ depuis huit ans, et soumis à des pertes importantes de biodiversité et de couvert forestier, est pris comme exemple. Trois études complémentaires ont été réalisées : i) le suivi de la déforestation en région tropicale humide et sèche par satellites, ii) l'estimation des stocks de carbone dans les sols et les forêts et iii) la modélisation des changements d'usage de terres. Nous avons développé une nouvelle méthodologie de suivi de la déforestation à Madagascar permettant de tenir compte de la définition des forêts et d'améliorer la prise en compte des petites parcelles de défriche brûlis. Les chiffres de la déforestation ont ainsi été actualisés jusqu'en 2013. Une méthodologie innovante de cartographie des stocks de carbone dans le sol à des résolutions fines et à des échelles régionales a été mise au point en couplant plusieurs facteurs environnementaux et des inventaires de terrain à l'aide d'un modèle d'arbres de « forêts aléatoire » (Random Forests). Ce modèle spatial du carbone a été appliqué sur des images satellites acquises vingt années plus tôt afin d'évaluer la dégradation des stocks de carbone du sol et leur régénération potentielle. Des facteurs de perte et gain de carbone dans le sol ont pu ainsi être estimés. Enfin, une approche de modélisation des changements d'usage des terres a permis de mieux comprendre les facteurs biophysiques et socio-économiques liés à la déforestation, dégradation des terres et régénération, et de proposer des scénarios spatialisés pour aider les décideurs. Les résultats obtenus dans cette thèse et les méthodologies développées permettent d'alimenter les discussions et documents concernant la stratégie REDD+ de Madagascar. Elle contribue plus largement à fournir des informations spatiales justes, précises spatialement et cohérentes à large échelle dans le but d'améliorer la gestion de nos écosystèmes terrestres.

Mots clés : REDD+, Madagascar, déforestation, biomasse, carbone du sol, modélisation spatiale, changement d'échelle, système de suivi

Abstract

Land use change due to agriculture and forestry, generates a significant loss of biodiversity and is an important part of our greenhouse gas (GHG) emissions causing climate change. The Reduction of Emissions from Deforestation and Forest Degradation, conservation, sustainable management and restoration of carbon stocks (REDD+) mechanism initiated ten years ago is struggling to establish because of many political and scientific constraints. Despite the existence of guidelines developed by the international scientific community, tools and data necessary to provide accurate, cost and usable at different scales. The objective of this thesis is to develop innovative methods to reduce uncertainties in the estimates of CO₂ emissions and sequestrations from deforestation, degradation and land regeneration. Madagascar, a country committed in REDD+ for eight years and subjected to significant losses of biodiversity and forest cover, is taken as an example. Three complementary studies were carried out: i) monitoring of deforestation in tropical humid and dry regions, ii) estimates of carbon stocks in soils and forests and iii) land use change model. We have developed a new methodology for monitoring deforestation in Madagascar considering the national definition of forests and accounted for small plots of slash and burn practices. The figures of deforestation vary from one region to another, and have been updated to 2013. An innovative methodology for soil organic carbon stock mapping at fine resolution and regional scale has been developed by coupling many environmental factors and a field inventory using a machine learning model. This spatial carbon model was applied on satellite images acquired twenty year ago to assess the degradation of soil carbon stocks and potential regeneration. Loss and gain factors due to various land use change were estimated. Finally, the land use change framework developed allowed us to understand the biophysical and socio-economic factors related to deforestation, land degradation and regeneration, and provide spatially scenarios to assist policy makers. The results obtained in this thesis and the methodologies developed allow to feed the discussions and documents relating to the REDD + strategy in Madagascar. It contributes and is aimed at a better management of agro-ecosystems by providing accurate spatial information, locally relevant and globally consistent.

Keywords : *REDD+, Madagascar, deforestation, biomass, soil carbon, spatial modeling, scale, monitoring system*

Acronymes

AFD : Agence Française pour le Développement

AFOLU: Afforestation, Forestation and Other Land Use

AR: Afforestation and Reforestation

BNC REDD+: Bureau National de Coordination REDD+ de Madagascar

COP: Conference of the Parties

CDP: Conference des Parties

CIRAD : Centre de coopération International en Recherche Agronomique pour le Développement

DGF: Direction Général des Forêts

FAO : Food and Agriculture Organisation

FCPF : Forest Carbon Partnership Facility

FFEM : Fonds Français pour l'Environnement Mondial

FRB : Fond de Recherche pour la Biodiversité

GES : Gaz à effet de serre

GDT : Gestion Durable des Terres

GFW : Global Forest Watch

GIEC : Groupe International d'Experts sur Climat

IEFN : Inventaire Ecologique et Floristique National

IPBES: Intergovernmental Science-Policy Platform on Biodiversity and Ecosystem Services

IPCC: International Panel of expert on Climate Change

IRD : Institut de Recherche pour le Développement

LiDAR: Light Detection and Ranging

MNP: Madagascar National Parks

NDVI : Normalized Difference Vegetation Index

ODD : Objectifs du Développement Durable

ONE : Office National de l'Environnement

RED : Réduction des Emissions de GES liées à la Déforestation

REDD+ : Réduction des Émissions de GES liées à la Déforestation et la Dégradation des forêts, l'accroissement des stocks de carbone et la gestion durable des terres

PERR FH: Programme Ecoregional REDD+ des Forêts Humides de Madagascar

PE3 : 3ème Plan Environnemental de Madagascar

SDG: Sustainable Development Goals

SEAS-OI : Surveillance de l'Environnement Assistée par Satellite pour l'Océan Indien

UN REDD: United Nations Programme on Reducing Emissions from Deforestation and Forest Degradation

UNFCCC: United Nations Framework Convention on Climate Change

UNCBD: United Nations Convention on Biological Diversity

UNCCD: United Nations Convention to Combat Desertification

VCS: Voluntary Carbon Standard

WCS: World Conservation Society

WWF: World Wild Fund

Chapitre 1 - Introduction générale

1	CONTEXTE, DÉFINITIONS ET CADRE MÉTHODOLOGIQUE	11
1.1	LA FORÊT, L'AGRICULTURE ET LE CLIMAT : DES ENJEUX ENTRE SCIENCE ET POLITIQUE.....	11
1.2	REDD+.....	13
1.2.1	<i>Historique et principes clés</i>	<i>13</i>
1.2.2	<i>La REDD+ à Madagascar.....</i>	<i>17</i>
1.3	CADRE MÉTHODOLOGIQUE	19
1.3.1	<i>Calcul des émissions de GES selon le GIEC</i>	<i>19</i>
1.3.2	<i>Niveaux d'incertitude</i>	<i>20</i>
2	PROBLÉMATIQUES SCIENTIFIQUES	22
2.1	SUIVRE LA DÉFORESTATION DES FORÊTS TROPICALES	22
2.2	QUANTIFIER LES STOCKS DE CARBONE DANS LES ARBRES ET LES SOLS	24
2.3	MODÉLISER LA DÉFORESTATION DANS LE FUTUR.....	27
3	OBJECTIFS ET PLAN DU MANUSCRIT	31
3.1	OBJECTIFS GÉNÉRAUX ET SPÉCIFIQUES.....	31
3.2	ZONE D'ÉTUDE	32
3.3	PLAN DU MANUSCRIT	34
3.4	MENTIONS ET NOTE AU LECTEUR	35
4	RÉFÉRENCES DU CHAPITRE 1	37

1 Contexte, définitions et cadre méthodologique

1.1 La forêt, l'agriculture et le climat : des enjeux entre science et politique

L'utilisation et le changement d'utilisation des terres jouent un rôle prépondérant dans la dégradation de nos écosystèmes et le dérèglement climatique. L'exploitation des forêts et l'agriculture sont les deux premières causes de perte de la biodiversité (Maxwel et al, 2016) et sont responsables d'un quart des émissions de gaz à effets de serre d'origine anthropique à l'échelle globale (IPCC, 2014b). En parallèle des évaluations de l'impact des activités humaines sur le climat par le Groupe d'experts intergouvernemental sur l'évolution du climat (GIEC) et dès sa création en 1988, une longue série d'accords et avancées politiques ont eu lieu au niveau international, principalement dans le cadre des trois conventions des Nations Unies sur le climat (UNFCCC, pour United Nations Framework Convention on Climate Change), la biodiversité (UNCBD, pour Convention on Biological Diversity) et la désertification (UNCCD, pour United Nations Conventions to Combat Desertification) (figure 1). C'est le cas notamment du mécanisme de Réduction des Émissions liées à la Déforestation et la Dégradation des forêts, l'accroissement des stocks de carbone et la gestion durable des terres (REDD+) initié en 2005 dans le cadre de l'UNFCCC. Le rôle de l'agriculture sur le climat et son lien avec l'usage des forêts a été plus récemment pris en considération au niveau international. Depuis quelques années, on assiste à une multiplication des objectifs et initiatives globales visant à réduire notre impact sur l'environnement, en combinant pratiques agricoles et usage de la forêt plus durables. C'est le cas par exemple de l'initiative *Climate-Smart Agriculture*, lancée lors de la *Conference of the Parties* (COP) à Copenhague en 2009, et plus récemment de l'initiative « 4 pour mille » à la COP de Paris en 2015.

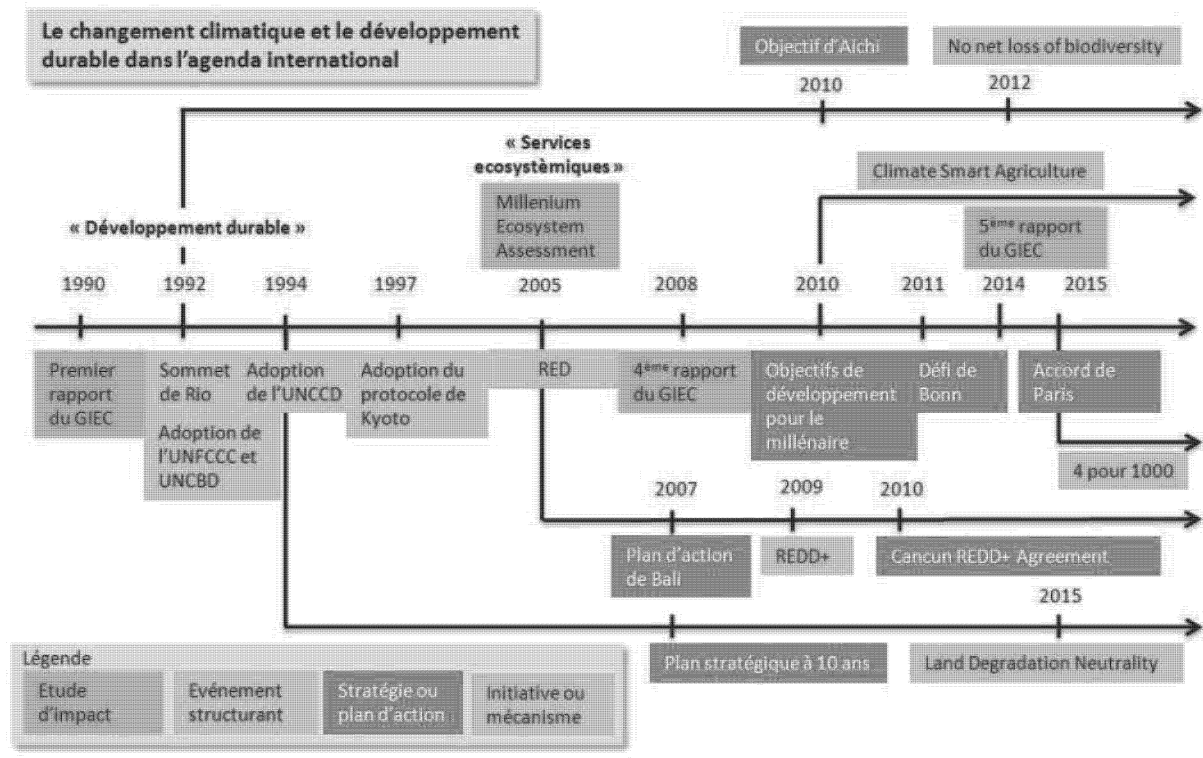


Figure 1 Illustration synthétique (non exhaustive) de la place du changement climatique et du développement durable dans les négociations internationales.

Toutes ces initiatives ou mécanismes visant à changer notre mode d'utilisation des terres s'appuient sur le concept de **services écosystémiques** porté au niveau international lors de l'évaluation des écosystèmes pour le millénaire en 2005 (Millennium Ecosystem Assessment, 2005). Cette notion implique l'identification et la quantification des services « offerts » par les écosystèmes pour répondre aux « demandes » des sociétés. Ces services pouvant concerner des demandes locales (ex. purification de l'eau par les sols), régionales (ex. provision de matériaux de construction) ou globales (ex. régulation du climat). La gestion des **biens publics mondiaux** s'organise aujourd'hui autour de cette idée de services écosystémiques, avec d'un côté les « politiques » au sens large qui fixent les objectifs, imaginent des mécanismes et implémentent des actions et de l'autre les scientifiques qui mesurent, suivent, modélisent les impacts et font des recommandations (figure 2). Les activités de « suivi-évaluation » font le lien entre science et politique car elles permettent d'adosser à l'action des critères de mesure d'indicateurs d'impact environnemental, économique et social. Ainsi, la mise en œuvre concrète des initiatives politiques pour changer notre trajectoire de développement nécessitent une réelle compréhension scientifique de ces services écosystémiques, notamment pour guider et évaluer l'impact des actions. Ces indicateurs, dont le carbone, doivent pouvoir être quantifié de manière précise et cohérente sur le territoire, selon des méthodologies reproductibles, assurant une transparence des résultats et un suivi dans le temps. L'agenda international sur la gestion de l'environnement pousse aujourd'hui de nombreuses sciences (foresterie, écologie, hydrologie, pédologie, géographie, etc.) à fournir

des informations environnementales avec une précision, une étendue géographique et une fréquence sans précédent.

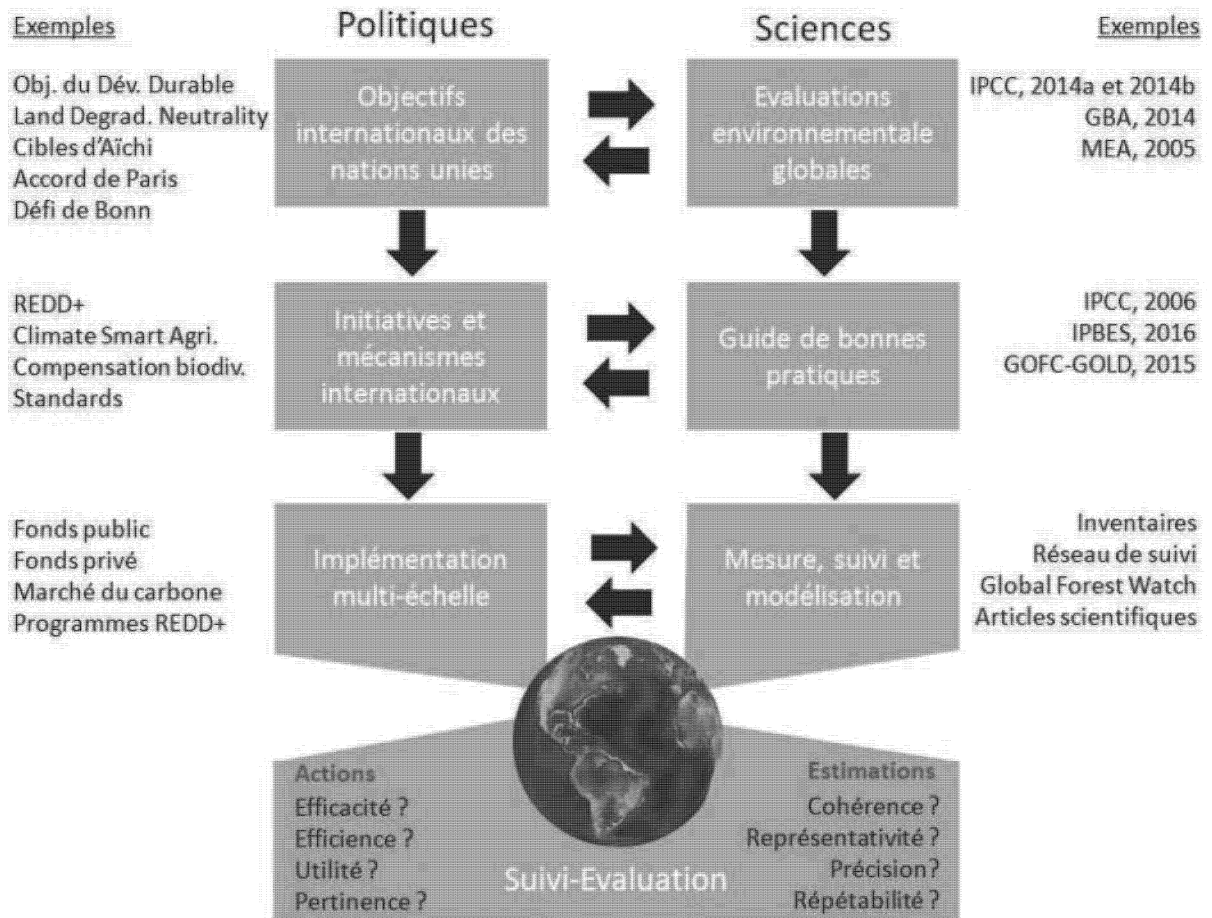


Figure 2 : Interface entre science et politique pour la gestion de l'environnement mondial.

1.2 REDD+

1.2.1 Historique et principes clés

Le rôle potentiel des forêts dans l'atténuation du changement climatique a été relayé en 2005 par un groupe d'acteurs nommé *Coalition of Rainforest Nations* mené par la Papouasie Nouvelle Guinée au cours de la onzième Conférence des Parties (COP 11) à Montréal. Cette proposition appelée REDD a été reprise deux ans plus tard dans le plan d'action de Bali (COP 13), ses règles et principes clés ont ensuite été précisés dans les accords de Cancun (COP 17). Ce mécanisme visant initialement uniquement la déforestation (RED) concerne aujourd'hui un grand nombre d'**activités de changement d'usage des terres** à l'interface forêt-agriculture (REDD+): déforestation, dégradation des forêts, gestion durable des forêts, conservation et renforcement des stocks de carbone forestier (tableau 1). La finalité de la REDD+ est d'inciter la diminution de certaines conversion d'usage (ex. déforestation) ou leur augmentation (ex. régénération des forêts) par le biais de **paiements sur résultats**. Ce

mécanisme ne fait pas partie des mécanismes définis et éligibles dans le cadre du protocole de Kyoto adopté en 1997, mais est considéré à partir de la deuxième période d'engagement du Protocole de Kyoto (post 2012). Aujourd'hui, le mécanisme REDD+ se traduit sur le terrain par l'existence de plus de 300 projets plus ou moins engagés dans un processus de certification carbone¹ (Simonet et al, 2015 ; figure 3) et la **mise en place de stratégie et plan d'action REDD+** nationale ou sous nationale (juridictionnelle) avec l'appui des Nations Unies (ex. Programme UN-REDD piloté par la FAO) ou de fonds carbone ad-hoc (ex. Forest Carbon Fund Facility – FCPF – piloté par la Banque Mondiale).

Plusieurs **principes clés** fédèrent ce mécanisme et sont par ailleurs source d'importants enjeux politiques, éthiques et scientifiques (Karsenty, 2008) : les fuites, l'additionnalité, la permanence et la mesure.

Fuites. Il s'agit des émissions de CO₂, ou d'autres GES, qui pourraient intervenir en dehors du périmètre d'intervention du projet ou programme, par exemple par déplacement des agents de la déforestation. Ce principe, impliquant de quantifier les fuites au-delà d'une zone d'action, vise à élargir les échelles d'intervention (du projet au programme) et alimenter des stratégies et plans d'action nationaux. Actuellement, à l'échelle mondiale, la moyenne des surfaces des projets REDD+ est de 300 000 ha (Simonet et al, 2015), des programmes REDD+ de plusieurs millions d'hectares sont en cours de définition dans des « pays REDD+ » (figure 3).

Additionnalité. Il s'agit d'évaluer la dynamique forestière en l'absence de projet REDD+. C'est un élément clé du mécanisme et des paiements sous-jacents, largement critiqué du fait de la complexité à prévoir cette dynamique (Karsenty, 2008). Il est basé sur le scénario de référence ou scénario *business-as-usual* (BAU). Ce critère implique une connaissance et de l'expertise dans de nombreux domaines (ex. foresterie, socio-économie, géographie, modélisation, etc.) et *in fine*, une transparence sur les hypothèses et mode de calcul pour établir les prévisions.

Permanence. Ce principe fait référence au fait que le carbone stocké dans les écosystèmes forestiers l'est de manière temporaire en raison du cycle de vie naturel des écosystèmes (ex. mortalité des arbres), des activités anthropiques ou d'événements naturels (ex. feux ou cyclones). Cela a amené les négociations sur la REDD+ à intégrer la notion de

¹ La **certification carbone** vise à établir des standards sur la qualité des estimations des bilans carbone d'une entreprise ou d'un projet. Il s'agit d'une démarche scientifique et technique, à l'initiative de l'entreprise ou du porteur de projet, suivant des méthodologies validées et reconnues, et réalisée par des organismes de certification habilités. Les standards les plus connus sont le Bilan Carbone® de l'Ademe en France et le Voluntary Carbon Standard (www.v-c-s.org) pour les projets portant sur la foresterie et l'agriculture (AFOLU) à l'échelle internationale.

risque, matérialisé sous forme de tampon (*buffer*) au niveau des crédits carbone. Cette notion implique également un suivi-évaluation continu et une redéfinition des scénarios de référence en cours de projet, généralement tous les dix ans.

Mesure. Les trois précédents principes impliquent d'établir un système de mesure, suivi, notification et vérification (SNV, *Monitoring, Reporting and Verification* - MRV en anglais) des dynamiques forestières sur de grands territoires. Ce système MRV oblige les pays ou projets à réaliser des inventaires de terrain (forestiers et pédologiques) et mettre en place des réseaux de mesure incluant des parcelles permanentes et autres méthodes de suivi (photo-interprétation, classification supervisée, etc.). La quantification du carbone stocké dans les arbres et les sols est complexe et sujette à de grandes incertitudes. Les sciences du vivant et sciences physiques sont fortement sollicitées dans le cadre de la REDD+ pour réduire les incertitudes. À titre d'exemple, il existe un guide de méthodes et procédures pour la mesure des émissions anthropiques liées aux activités forestières et agricoles (GOFC-GOLD, 2015). Il est établi à partir d'un consortium d'experts, inspiré des lignes directrices du GIEC (IPPC, 2006) et **mis à jour tous les ans** en fonction des avancées scientifiques et technologiques. Ces méthodes s'appuient très largement sur les données et outils de la télédétection qui fournissent une information biophysique objective, exhaustive sur les territoires, et répétée dans le temps.

Ces quatre principes ont été entérinés dans plusieurs décisions prises au cours des COP, dont les principales concernant la REDD+ sont présentées ci-dessous:

La **COP 15** (décision 4/CP15) indique que les parties doivent:

- Mettre en place des systèmes nationaux solides et transparents de surveillance des forêts, en utilisant une combinaison de données de télédétection et des mesures au sol pour estimer les émissions anthropiques de GES;
- Le système de suivi doit fournir des estimations qui soient transparentes, cohérentes, le plus exactes possible et qui réduisent les facteurs d'incertitude;
- Les résultats du suivi doivent être disponibles et faire l'objet d'un examen par l'UNFCCC.

La **COP 16** (Cancun Agreement) réaffirme que les parties doivent:

- Développer des systèmes nationaux solides et transparents de surveillance des forêts pour le suivi et notification des activités REDD+;
- Établir des niveaux d'émission de référence et/ou de niveau de référence;
- Implémenter la REDD+ par phase, en débutant par une phase de préparation des activités et évoluant vers des actions REDD+ basées sur des résultats complètement mesurés, notifiés et vérifiés.

La **COP 19** (Décision 15/CP19) indique que :

- Les parties doivent développer des stratégies nationales ou plan d'action afin d'adresser les facteurs de la déforestation et dégradation des forêts;
- Ces facteurs peuvent avoir plusieurs causes et les actions à entreprendre pour prendre en compte ces facteurs sont uniques à chaque pays, en fonction de ces capacités et compétences;
- Les parties, organisations pertinentes, secteur privé et autres parties prenantes sont invités à continuer leur travail pour adresser les facteurs de la déforestation et dégradation des forêts et partager leurs résultats;

La **COP 21** (Accord de Paris, article 5) indique que les parties doivent:

- Prendre des mesures pour conserver, et le cas échéant, renforcer les puits et réservoirs de gaz à effets de serre;
- Appliquer et étayer, par des versements sur résultats, les démarches générales et mesures d'incitations positives liées aux activités REDD+ et les démarches conjointes d'atténuation et adaptation pour la gestion intégrale et durable des forêts ;
- Promouvoir les avantages non liés au carbone

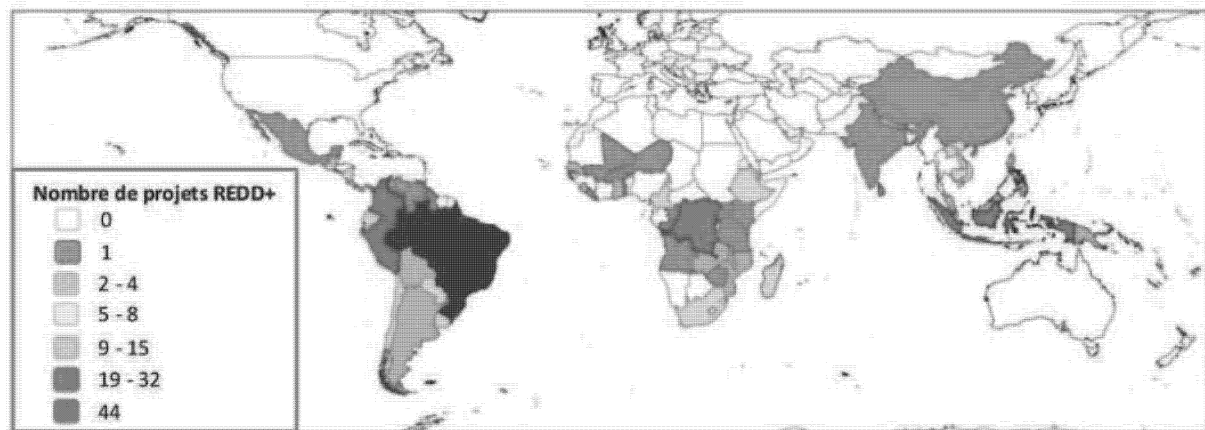


Figure 3. Localisation des projets REDD+ en 2014. Simonet et al, 2015

Parallèlement aux avancées des négociations internationales sur la REDD+, un marché volontaire de crédit carbone s'est mis en place, ainsi qu'un système de certification et de labellisation. Le plus utilisé par les porteurs de projet REDD+ est le *Voluntary Carbon Standard* (VCS). Cette certification des crédits carbone REDD+ s'appuie sur des méthodologies développées par des organismes internationaux, privés ou publics, plus ou moins liés à la recherche scientifique. Il existe aujourd'hui quatre méthodologies REDD+ validées concernant la déforestation dite « non-planifiée » et qui correspond à toute forme de déforestation et dégradation hors des concessions forestières officiellement enregistrées (Shoch et al, 2013 : VCS, 2016). Toutefois, elles sont généralement conçues sur la base de

l'expérience de projets pilotes difficilement répliquables, ou sont au contraire très génériques, laissant place à des nombreuses approximations.

Dans cette thèse nous avons voulu apporter, via une approche scientifique, des innovations technologiques (utilisation des images satellites, techniques de modélisation) et thématiques (intégration du sol, intégration des processus de dégradation des terres et régénération dans les scénarios) afin d'améliorer ces méthodologies et plus largement, de proposer des outils de gestion des terres applicables aux pays souhaitant développer leur stratégie REDD+ comme c'est le cas à Madagascar.

1.2.2 La REDD+ à Madagascar

Afin de protéger son incroyable biodiversité (Goodman et Benstead, 2005) et de disposer des moyens pour mettre en place des actions de réduction de la déforestation, **Madagascar s'est engagé dans le mécanisme REDD+ depuis 2008** avec l'aide du Facility Forest Carbon Partnership (R-PIN Madagascar, 2008). Au cours de cette thèse, le gouvernement Malgache a créé en 2014 le Bureau National de Coordination REDD+ et fait valider son plan de préparation national pour la REDD+ auprès du FCPF (RPP Madagascar, 2014). Il prévoit notamment d'améliorer et de mettre en place de nouveaux outils de gouvernance de la ressource forestière, d'identifier les causes et facteurs de la déforestation par régions et de décliner un plan d'action ou stratégie REDD+. Parallèlement, les scénarios de référence des émissions et scénario liés au plan d'action seront évalués. Enfin, Madagascar a récemment proposé une note d'intention pour développer un programme de réduction des émissions à l'échelle régionale au niveau des forêts humides de l'est (ER-PIN, 2015).

Depuis 2009, quatre projets pilotes REDD+ implémentent des actions de terrain et études scientifiques dans différentes régions de l'île (figure 4). Malgré leurs finalités différentes (vente de crédit carbone, développement de méthodologie, appui à la stratégie nationale), tous impliquent l'établissement de scénario de référence d'émissions de CO₂. Il existe des grandes différences entre les méthodologies utilisées par les projets, en termes de données, échelles et méthode de modélisation des changements d'usage des terres (RPP Madagascar, 2014). Cela complexifie le choix de la méthodologie pour le pays, pourtant nécessaire au regard des objectifs gouvernementaux et l'établissement d'un système MRV.

L'état de l'art des protocoles de mesure et rapportage des émissions/séquestrations de GES liés au changement d'usage des terres est en constante évolution (outils pour faciliter ou réduire le coût des inventaires terrains, méthode de traitement des données satellites, etc) du fait des progrès technologiques (GOFC-GOLD, 2015). Des défis technologiques existent pour le choix ou le développement de méthodologies adaptées aux conditions du pays. Madagascar est un grand pays (superficie de la France plus la Belgique et les Pays-Bas) marqué par des

climats très contrastés (de per-humide avec des précipitations >3000 mm à aride avec des précipitations < 500 mm par an), et des reliefs très escarpés pour les régions où il reste des forêts humides intactes. La ressource forestière est fortement sollicitée par les populations rurales, pour ouvrir des nouveaux terrains de culture, fournir des matériaux de construction, le bois de chauffe ou encore pour l'extraction minière illégale. Les techniques de suivi de la ressource forestière doivent être adaptées pour prendre en compte le contexte biophysique (forte nébulosité et relief escarpé) et les particularités des activités anthropiques qui menacent les forêts de Madagascar (faible surface, mosaïque de culture, jachère et savane), différentes de celles du Brésil ou de l'Indonésie (grandes cultures de soja ou palmier à huile) ou du Congo (grandes exploitations forestières).

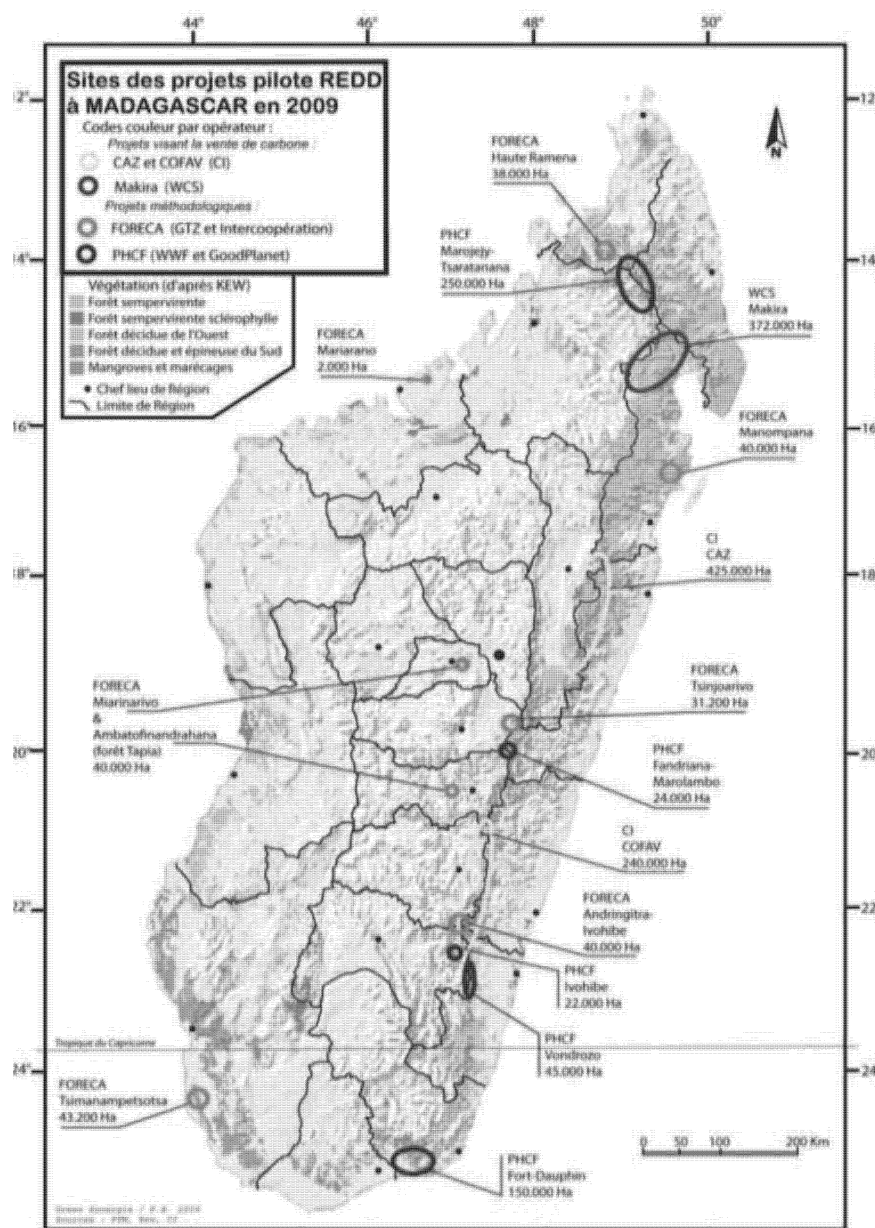


Figure 4: Localisation des projets pilotes REDD+ en 2009. Source : RPP Madagascar, 2014.

1.3 Cadre méthodologique

1.3.1 Calcul des émissions de GES selon le GIEC

Dans cette thèse, nous avons suivi le cadre méthodologique proposé par le GIEC décrits dans deux documents de référence (IPCC, 2006 ; GOFC-GOLD, 2015). Le niveau ou scénario de référence des émissions de GES - produit à l'échelle globale par le GIEC - peut être résumé à travers cette question : « quelles seront les émissions de CO₂ dans le futur en tenant compte de nos activités actuelles et du fonctionnement des écosystèmes ? » Il guide les négociations internationales sur le climat et a été repris dans le principe fondateur du protocole Kyoto, à savoir le principe de l'additionnalité (voir définition plus haut). Plus localement, il s'agit d'estimer les émissions de CO₂ en l'absence d'un projet afin de pouvoir calculer les effets et impacts « réels » liés à ce projet. Dans le secteur des « Terres » (agriculture, foresterie et changement d'utilisation des terres ou AFOLU) le mode de calcul des émissions est simple et se présente comme suit :

$$E = AD * EF$$

Avec E les émissions de CO₂ en tonnes de CO₂ équivalent (t CO₂ eq), AD les **données d'activités** (superficies et variations de superficies, en hectares) et EF les **facteurs d'émissions** (stocks de carbone et variations de stocks de carbone, en tonnes de carbone par hectare).

Ce mode de calcul constitue la base des outils de bilan carbone et peut être utilisé dans la plupart des travaux de compatibilité environnementale (Weber, 2014). La construction d'un scénario ou niveau de référence des émissions nécessite d'estimer les données d'activités (historiques et futurs) et facteurs d'émissions pour l'ensemble des conversions d'usages (figure 4). Il existe deux méthodes pour estimer les émissions de GES des activités : la **méthode de différence de stock** (*stock-difference*) entre un temps 0 et un temps +1 ou la **méthode de mesure des gains et pertes** à un temps t (*gain-loss*). Le choix de la méthode dépend en pratique de l'activité que l'on souhaite quantifier. En ce qui concerne le secteur agricole et forestier (AFOLU), les activités ainsi que leur mode de calcul privilégié sont résumés dans le tableau 1.

Dans cette thèse nous nous sommes intéressés particulièrement à la quantification de l'activité déforestation (conversion des forêts primaires en terres cultivées) et aux facteurs d'émissions liés au compartiment sol. Ce compartiment difficile d'accès est souvent peu quantifié bien qu'il soit un indicateur synthétique de la santé des écosystèmes communément accepté.

ACTIVITÉS REDD+ et autres changements d'usage des terres		Terres forestières		Terres cultivées	
En (état d'arrivée)					
De (état initial)		Forêts (naturelles) intactes	Forêts anthropisées	Champ de culture ou jachère ou prairie	
Terres forestières	Forêts (naturelles) intactes	Préservation de la forêt	Dégradation de la forêt	Déforestation	REDD+
	Forêts anthropisées	Régénération naturelle	Gestion durable des forêts	Déforestation ou dégradation *	
Terres cultivées	Champ de culture ou jachère ou prairie	-	Régénération naturelle ou boisement	Gestion durable des terres cultivées	AR et GDT

En vert : méthode gain-loss **en Orange** : méthode stock difference

Tableau 1 : Matrice des activités REDD+, Afforestation et Reforestation (AR) et Gestion durable des terres (GDT), adapté d'après les catégories du GIEC (IPCC, 2006). Les activités en orange sont estimées par des approches de différence de stocks entre la situation initiale et situation d'arrivée (stock difference). Les émissions des activités en vert, sont estimées par des approches de « gains-pertes ». * Selon la définition adoptée par le pays.

1.3.2 Niveaux d'incertitude

On voit assez facilement d'après le tableau 1 l'ampleur de la tâche de quantification des scénarios de référence REDD+ : à la fois sur la définition des catégories d'usage des terres et sur les méthodes de quantification prenant en compte l'espace et le temps. En 2006, le GIEC a proposé une série de bonnes pratiques pour la quantification des émissions de GES (IPCC, 2006). Ce rapport définit notamment trois niveaux d'incertitude pour caractériser les données d'activité (AD) et les facteurs d'émissions (EF):

- **Niveau 1** (tiers 1) correspond aux valeurs par défaut du GIEC, issues de la littérature scientifique à l'échelle mondiale;
- **Niveau 2** (tiers 2) correspond aux valeurs issues d'études au niveau régional ou national;
- **Niveau 3** (tiers 3) correspond aux valeurs mesurées localement, répétées dans le temps ou issues de modélisation.

Passer du niveau 1 au niveau 3 augmente la justesse et la précision des estimations, mais augmente également la complexité et le coût du suivi (Baker et al, 2010). L'incertitude est un paramètre clé des politiques de compensation environnementale comme la REDD+ car elle

affecte la crédibilité et la recevabilité d'éventuels paiements sur résultats (ex. crédit carbone). Selon les données et outils utilisés, l'évaluation de l'impact du projet ou politique peut être complètement « engluée » dans l'incertitude. Des auteurs ont rapporté qu'au niveau du Panama, le scénario le plus ambitieux (50% de réduction de la déforestation) ne serait détectable qu'au bout de douze années après le début du projet en tenant compte des incertitudes du scénario de référence (Peletier et al, 2011).

Les sources d'incertitudes associées aux scénarios de référence sont nombreuses et se situent autant au niveau des données d'activités que des facteurs d'émissions. Peletier et al (2011) ont rapporté que l'estimation des stocks de carbone de la biomasse pouvait être à l'origine de 50% de l'incertitude sur les émissions du fait du choix de la méthodologie d'inventaire terrain et de l'équation allométrique utilisée. Une autre étude a récemment démontré que la définition des catégories de modes d'usage des terres et la méthode de modélisation des changements d'usages des terres futures étaient les facteurs d'incertitude les plus importants dans la construction de scénarios d'émissions de GES (Prestele et al, 2016).

Cette prise en compte pragmatique des niveaux d'incertitude (niveau 1, 2, 3) permet de stimuler la recherche pour améliorer nos connaissances sur la dynamique des écosystèmes. Par ailleurs, il ne compromet pas la mise en œuvre de la REDD+, car les politiques et développeur de projet sont tenus de respecter le principe d'**estimations conservatrices** (Grassi et al, 2008). Ce principe indique que toutes les estimations (activités ou facteurs d'émissions) doivent être accompagnées d'une estimation de l'erreur. L'impact (figure 5), c'est-à-dire la réduction des émissions de CO₂ et les paiements associés à ces résultats sont calculés en fonction de cette erreur, afin de retenir une valeur « conservatrice », qui ne surestime pas les émissions de CO₂ évitées ou générées par le projet, programme ou politique.

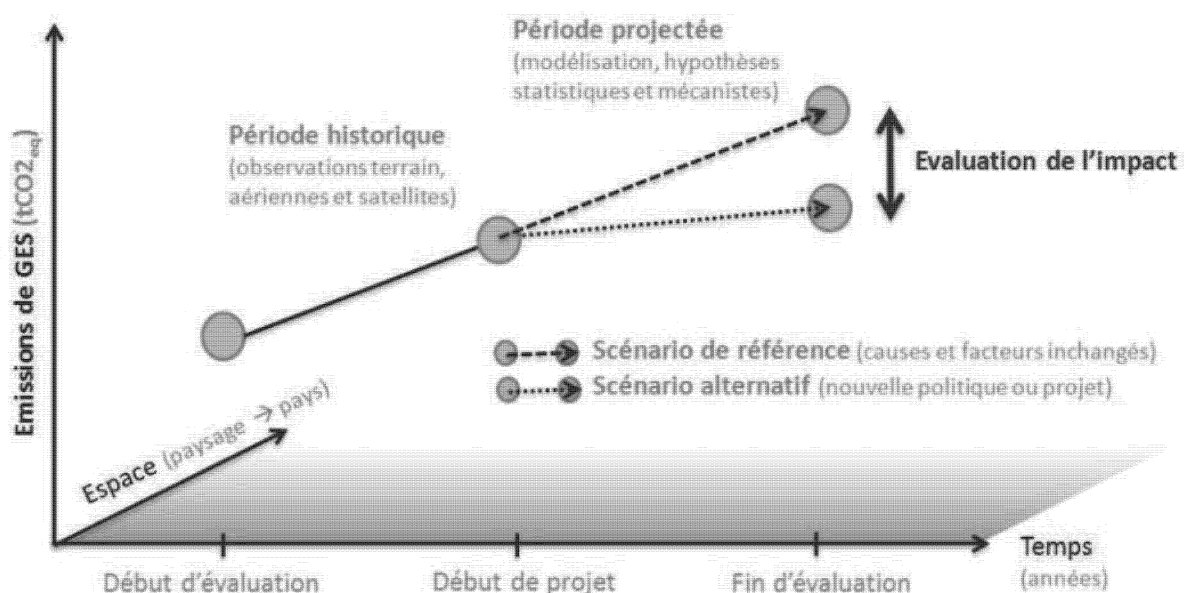


Figure 5 : Illustration de l'évaluation de l'impact climatique à l'échelle d'un territoire.

2 Problématiques scientifiques

Dans cette thèse, nous avons développé des méthodologies visant à limiter l'incertitude des scénarios de référence dans le but de proposer une approche scientifique permettant d'obtenir des estimations atteignant le *niveau de précision 3* à Madagascar. Comme indiqué ci-dessus, ces incertitudes se situent principalement à trois niveaux: le suivi de la déforestation, la quantification du carbone contenu dans les écosystèmes terrestres et la modélisation des changements d'utilisation des terres. Les explications de ces incertitudes - ou manques actuels de connaissances - sont présentées plus en détail ci-dessous.

2.1 Suivre la déforestation des forêts tropicales

Le suivi des changements de surfaces forestières avec des images satellites et techniques de télédétection est aujourd'hui considéré comme opérationnel à toutes les échelles (De Sy et al, 2012). C'est le cas pour le Brésil et l'Inde qui disposent d'un système de suivi satellite de la couverture forestière qui produit des cartes et statistiques tous les ans ou deux ans à l'échelle du pays. À l'échelle globale, il existe deux systèmes de suivi qui font aujourd'hui référence : le Forest Resource Assessment de la FAO (FRA, 2015) qui produit des statistiques tous les cinq ans, et le Global Forest Watch (GFW) issu des travaux d'Hansen et al (2013) qui produit des statistiques tous les ans. Si les barrières technologiques semblent levées, il persiste néanmoins de grandes disparités entre les études sur un même territoire, produisant des résultats différents (Hansen et al, 2013). Les raisons sont diverses:

Tout d'abord la **définition de la forêt** est un élément décisif des études de suivi de la déforestation. Le FRA enregistre les changements permanents au niveau de l'usage des terres, la coupe et régénération forestière faisant parti du cycle de rotation d'une forêt gérée. Il considère également les espèces forestières peu ou non ligneuses, comme certaines plantations, qui sont des cultures agricoles pérennes et non des forêts selon d'autres approches. A l'inverse, le GFW considère toutes les pertes de couvert forestier à un moment donné, dès lors qu'il y a eu une coupe rase. Il ne s'agit pas non plus de forêt au sens de la définition nationale d'une forêt mais d'une surface avec couverture arborée. Une forêt naturelle dense ou parcelle agroforestière avec quelques arbres est alors considérée comme forêt dans cette étude (figure 6). Chaque pays engagé dans la REDD+ est tenu de définir ses seuils minimaux selon une gamme de valeur défini par l'UNFCCC (

tableau 2).

Les systèmes de suivi des forêts diffèrent également selon leurs **méthodes d'estimation des surfaces forestières**. Dans le cas du FRA, il s'agit de déclarations nationales, basées sur des inventaires nationaux réalisés au sol, à partir de points d'observations et/ou images satellite. Cette méthode suit une approche « point-sampling », par échantillonnage de points ou placettes à l'instar de l'étude de Achard et al (2014). Le GFW s'appuie uniquement sur des données d'images satellite, et des mesures à l'échelle du pixel (30 m). Cette méthode fait référence à une technique dite « wall-to-wall », par couverture exhaustive.




Figure 6 : Illustration des différences de définition entre deux systèmes globaux de suivi des forêts. Source : www.landscape.org

Tableau 2. Définitions des seuils minimaux pour l'identification des forêts selon l'UNFCCC, la FAO et Madagascar

Critères	UNFCCC	FAO	Madagascar
Surface de terres (ha)	> 0,05 à 1	> 0,5	> 1
Couverture de la canopée (%)	> 10 à > 30	> 10	> 30
Hauteur des arbres à maturité (m)	> 2 à 5	> 5	> 5

Il n'existe pas aujourd'hui de système national de suivi des forêts à Madagascar. Plusieurs études de cartographie de la déforestation ont été réalisées à l'échelle nationale : Harper et al (2007) pour les périodes 1950-1975-1990-2000 et MEFT et al (2009) pour les années 1990-

2000-2005. Ces études montrent cependant certaines limites : elles ne tiennent pas compte de la définition de la forêt nationale, nécessaire pour alimenter les discussions sur la REDD+, sont marquées par des surfaces importantes sous nuage et ne tiennent pas compte des surfaces défrichées en dessous de un hectare (unité minimal de cartographie) ce qui peut entraîner une sous-estimation des pertes forestières réelles.

Cette thèse vise à proposer une méthode de suivi des forêts applicable sur tout le pays et adaptée aux circonstances nationales (définition des forêts, localisation de la déforestation, capacités techniques).

2.2 Quantifier les stocks de carbone dans les arbres et les sols

L'estimation des stocks de carbone dans les arbres et le sol est plus difficile car elle s'appuie nécessairement sur un travail d'inventaire de terrain, souvent long, coûteux et fastidieux. Il est possible cependant d'optimiser ce travail d'inventaire et réduire les coûts de la mesure à l'hectare à partir de techniques combinant images satellites et inventaires de terrain. A l'échelle pan-tropicale, deux études de quantification spatialisée des stocks de carbone de la biomasse (Saatchi et al, 2011 ; Baccini et al, 2012) font référence. Elles ont été produites à l'aide de données satellites similaires (données MODIS et données LiDAR) mais avec des données terrains (inventaires forestiers, équations allométriques) et des techniques de modélisation spatiales différentes. Une étude montre que les différences d'estimation de la biomasse entre ces deux cartographies sont considérables et qu'il y a peu de cohérence entre l'amplitude et la direction des différences (Mitchard et al, 2013 ; figure 7). Une autre étude plus récente, combinant les deux études précédentes avec d'autres données d'inventaire pour la calibration et validation a mis en évidence que ces études surestimaient de 9 à 18% les stocks de carbone dans la biomasse aérienne (Avitabile et al, 2016). Des méthodes existent pour réduire ces incertitudes à l'échelle régionale, à l'aide de couplage entre des inventaires terrains spécifiques (sur la zone à caractériser) et données satellites optique basse résolution (Le Maire et al, 2011a), très haute résolution (Vagen et Winowiecki, 2013), hyperspectrale (Gomez et al, 2008), ou données aéroportées LiDAR (Asner et al, 2012 ; figure 8).

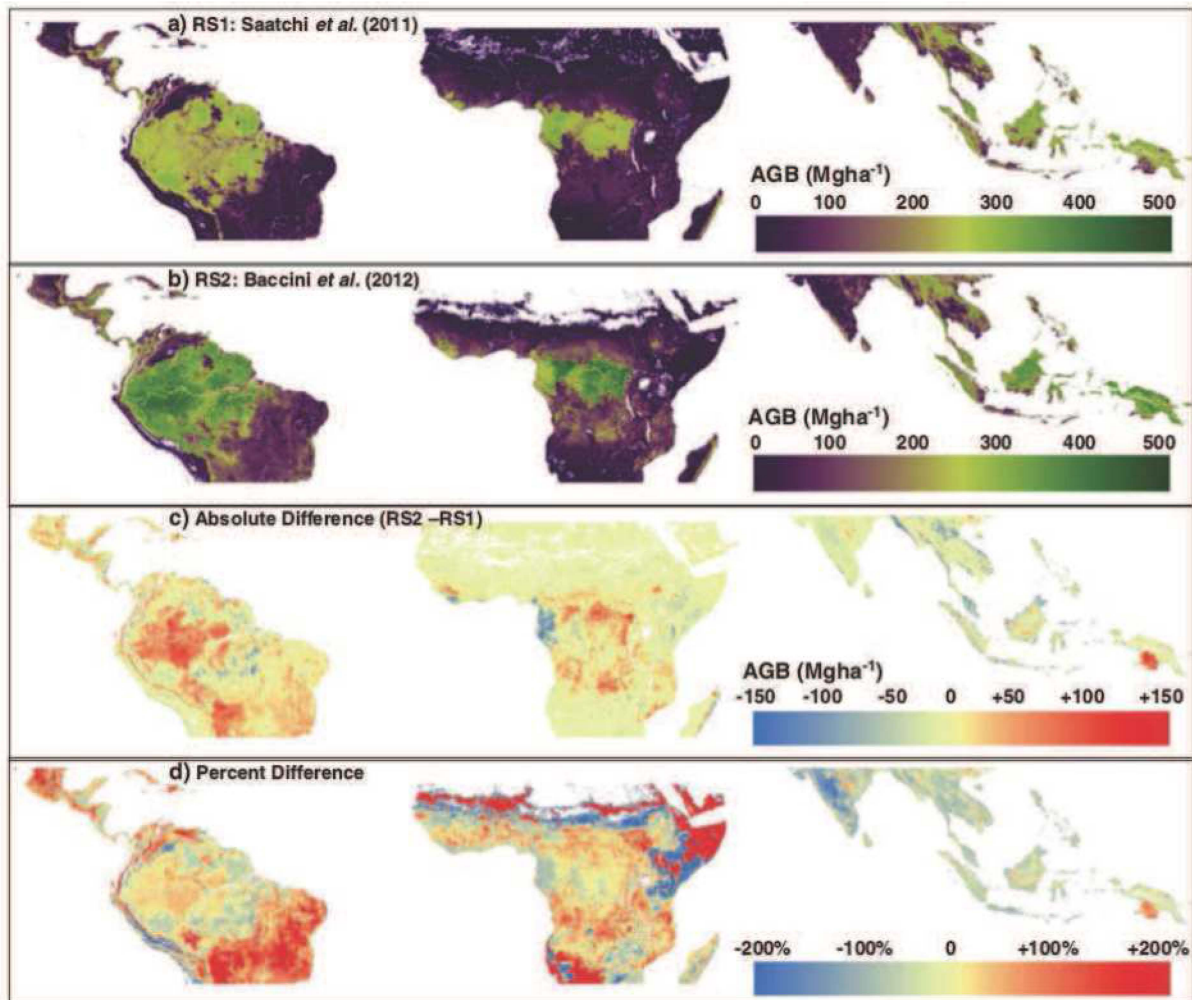


Figure 7. Comparaison de deux cartographies de la biomasse aérienne (AGB) par satellites dans la ceinture inter-tropicale : a) AGB de la carte de Saatchi et al 2011. b) Carte AGB de Baccini et al, 2012. c) la différence absolue entre a et b. d) le pourcentage de différence entre les deux cartes. Extrait de Mitchard et al, 2013.

La plupart des études sur des scénarios de référence d'émissions de CO₂ exclut le compartiment sol. Il existe des cartes mondiales de stocks de carbone du sol au 1:5 000 000^{ème} (FAO, 2002) mais elles sont peu ou pas utilisables à l'échelle d'un pays. Des initiatives sont en cours pour créer, à l'instar des cartes pantropicales de la biomasse, des cartes des propriétés des sols cohérentes globalement et pertinente localement (www.globalsoilmap.net). A Madagascar, une première carte des stocks de carbone du sol sur 0-30 cm a été produite (Grinand et al, 2009) en suivant une méthode développée au Brésil (Bernoux et al, 2002). Cette cartographie nationale a été réalisée par intersection entre des données d'inventaire historique (période 1940-1975), une carte de sol nationale et une carte de végétation issue du traitement de données satellites. Elle n'est cependant pas utilisable en dessous de l'échelle nationale (1:1 000 000^{ème}). Il n'existe pas aujourd'hui i) de méthodologie à Madagascar permettant de quantifier le carbone du sol à des échelles « opérationnelles » (paysage, région),

ni ii) de données sur la dynamique du carbone du sol post-déforestation dans les paysages forestiers et agricoles.

Le sol est pourtant un compartiment de carbone important à l'échelle de la planète, représentant environ quatre fois celui de la végétation et deux fois celui de l'atmosphère (IPPC, 2014a). Il peut constituer à la fois un puit ou une source de carbone importante selon l'affectation et le changement d'affectation des terres. Au-delà de l'impact climatique (émission ou séquestration de tCO_2eq), le carbone organique du sol est un proxy de nombreux services écosystémiques, dont la production végétale, le contrôle de l'érosion et la rétention en eau. La quantification du carbone organique dans le sol peut être fastidieuse et coûteuse, ce qui explique la faible prise en compte de cette ressource dans les politiques de gestion des terres. Cependant des progrès technologiques récents ont été réalisés notamment en termes de technique de mesure des propriétés des sols directement sur le terrain comme les spectromètres infra rouge et en termes de cartographie numérique des sol utilisant toute la richesse des données satellites d'observation de la terre (Mulder et al, 2011 ; Minasny et al, 2013 ; Gomez et al, 2008). Ces développements récents permettent d'envisager la cartographie des sols d'un point de vue opérationnel (Lagacherie et al, 2008).

Cette thèse vise à proposer une méthode d'estimation du carbone (forestier et sols) à l'échelle régionale et nationale d'une part et d'autre part d'estimer les facteurs d'émissions du sol liées à la déforestation.




Figure 8. Illustration d'une méthode de cartographie innovante de la biomasse aérienne, à partir de technologie lidar aéroporté. Extrait de Asner et al, 2012. L'image de gauche représente le plan d'inventaire des placettes forestières (points rouges) et le plan de vol de l'avion avec le Lidar embarqué (rectangle blanc). L'image au centre illustre la carte produite après traitement des données Lidar (hauteur moyenne des arbres) à une résolution métrique. L'image à droite est la carte régionale de biomasse obtenue après extrapolation sur la base de facteurs environnementaux spatialisés (indice de végétation et altitude).

2.3 Modéliser la déforestation dans le futur

La projection de la déforestation dans le futur est un sujet primordial, déterminant à la fois les politiques forestières et agricoles à mettre en œuvre et les potentiels financements carbone. Il n'existe pas aujourd'hui de méthodes ni de bonnes pratiques clairement établies ou communément acceptées pour l'établissement de scénarios de déforestation dans le futur, que ce soit au niveau du GIEC ou du GOFC-GOLD. Le sujet est particulièrement complexe car il nécessite de comprendre et quantifier la diversité des interactions entre les environnements naturels et humains qui sont à l'origine des changements.

Il existe deux grandes familles de modèles spatialisés permettant de caractériser les changements d'usages des terres (Castella et Verburg, 2007): ceux basés sur les processus (*process-based*) et ceux basés sur les formes de changements (*pattern-based*). Les modèles du premier type impliquent la définition des agents, facteurs et interactions par expertise scientifique et connaissances locales. Ils décrivent un fonctionnement général et compréhensif, nécessitant peu de données mais beaucoup de paramètres et hypothèses. Le deuxième type de modèle consiste à développer des relations statistiques entre les observations de changements et les facteurs, pour la plupart géolocalisés. Ces modèles permettent de quantifier l'importance des facteurs, spatialiser les résultats, mais ils nécessitent beaucoup de données. On parle aussi pour la première famille de modèle mécaniste basé sur les agents (*agent-based models*), et pour l'autre de modèle statistiques guidé par les données (*data-driven models*).

Chacune de ces approches possèdent donc des avantages et des inconvénients, tandis qu'aucune ne parvient à capturer toute la complexité des mécanismes (Veldkamp and Lambin, 2001). Dans le cadre de la REDD+, trois des quatre méthodologies actuellement acceptées au Voluntary Carbon Standard (Shoch et al, 2012) préconisent de modéliser *spatialement* la déforestation future en se basant sur des régressions statistiques (deuxième famille de modèles). Cette démarche est globalement la plus utilisée (Mas et al, 2007) car elle permet i) d'identifier et de hiérarchiser les causes et facteurs sur lesquels des actions peuvent être entreprises et ii) de produire des cartes avec un ciblage géographique des actions et la vérification objective des projections. Une méta-analyse récente, s'appuyant sur 117 études spatiales de la déforestation publiées entre 1996 et 2013, a étudié ce qui favorise ou freine la déforestation (« *What Drives Deforestation and What Stops It?* » Ferretti Gallon and Bush (2014)). Les auteurs concluent cette étude en attestant que plus les retombées économiques de l'agriculture sont élevées par rapport à l'usage ou au maintien de la forêt, plus la déforestation est élevée. Cela est dû soit à des conditions climatiques et topographiques favorables, soit aux coûts réduits d'exploitation en fonction de la mécanisation ou des infrastructures de transport vers les marchés. Malgré ce constat, les facteurs de la déforestation communément étudiés ont

des effets généralement contradictoires d'une région à l'autre, souvent non significatifs (figure 9) et les liens réels de causalités restent difficiles à appréhender.




Figure 9: Vingt causes de la déforestation les plus étudiées, organisée par sens et significativité à partir d'études de régression multivariées. Extrait de Ferretti Gallon et Bush (2014). Les causes en lettres capitales indiquent les causes dont l'effet (positif ou négatif) est significatif (test-t à 95% d'intervalle de confiance).

À Madagascar, la première étude réalisée sur les causes et facteurs de la déforestation à l'échelle nationale montre des résultats intéressants et parfois surprenants. Contrairement aux explications habituellement apportées, Gorenflo et al (2010) indiquent qu'il n'y a pas d'effets significatifs ni de la densité de population rurale, ni du niveau de pauvreté sur la déforestation. Des tendances nettes de réduction de la déforestation ont été observées dans les aires protégées, jusqu'à moitié moins dans une zone protégée comparée à une zone non protégée. Ensuite, l'accessibilité de la ressource forestière (exprimée à travers trois variables : proximité des routes, pistes et pente du terrain) est fortement associée à la déforestation. Enfin, les dynamiques varient régionalement : le sud-ouest de Madagascar enregistre les plus forts taux de déforestation en particulier du fait de la production de maïs pour les industries locales et le marché international (Casse et al, 2004), ce commerce étant réduit au marché local dans les autres régions.

Ces approches s'appuient sur un modèle logistique qui implique des relations linéaires et peut être biaisé lorsqu'on utilise des variables explicatives avec des granularités différentes (Gorenflo et al, 2010). Les données socio-économiques sont trop limitées et peu prises en compte. Elles sont souvent agrégées à des niveaux administratifs, obsolètes et non évolutifs (le seul recensement officiel date de 1993 à Madagascar et pour les anciennes délimitations des communes). Elles sont analysées au même plan que des variables à des échelles nettement inférieures (variables biophysiques ou de distance à l'échelle de la dizaine ou centaine de mètres). Enfin, ces études couvrent une période de déforestation maintenant ancienne, allant de 1990 à 2000, sans proposer de projection future. Aucune autre étude n'a été réalisée à l'échelle nationale pour la dernière décade, à des fins de prospective territoriale. Une étude récente à l'échelle régionale portant sur la période 2000-2010 a proposé une méthode de projection spatialisée de la déforestation future jusqu'en 2030 (figure 10; Vieilledent et al, 2012). Les auteurs ont démontré et utilisé la corrélation entre densité de population à l'échelle régionale et déforestation pour établir les scénarios d'évolution des taux de déforestation.

L'ensemble de ces recherches s'appuient sur des modèles linéaires par essence limités lorsqu'il s'agit de capturer les effets de variables biophysiques et socio-économiques à des fins prospectives. Les processus en jeu ne sont intrinsèquement pas linéaires (Veldkamp and Lambin, 2001). Une solution est alors d'utiliser de nouveaux outils, comme les algorithmes d'apprentissage automatique (*machine learning*) qui peuvent modéliser des problèmes complexes, incluant des conditions et des relations non linéaires. Ils nécessitent peu de paramétrisation ou d'hypothèses statistiques sur les relations entre variables. Une étude récente a montré la possibilité d'utiliser un algorithme d'apprentissage automatique (MAXENT) pour la modélisation de la déforestation avec des résultats satisfaisants (Aguilar-Amuchastegui et al, 2014). Une autre analyse s'est appuyée à la fois sur des modèles de régression linéaire et d'arbre de décision pour confirmer les résultats et fournir plus d'explications sur leur importance (De Fries et al, 2010). Mis à part quelques exemples, ces nouveaux outils n'ont pas été testés pour la modélisation et la projection de la déforestation. Une autre limite des études de modélisation de la déforestation est qu'elles se focalisent généralement sur ce seul processus de changement dans le paysage: la déforestation. L'intégration des autres processus clés de changement d'usage comme la dégradation et la régénération permet de construire des scénarios plus complets sur les menaces et opportunités afin de proposer plusieurs alternatives aux décideurs.

Dans cette thèse nous proposons d'explorer d'autres outils de modélisation qui n'ont pas encore été testés, tout en intégrant d'autres conversions d'usage.

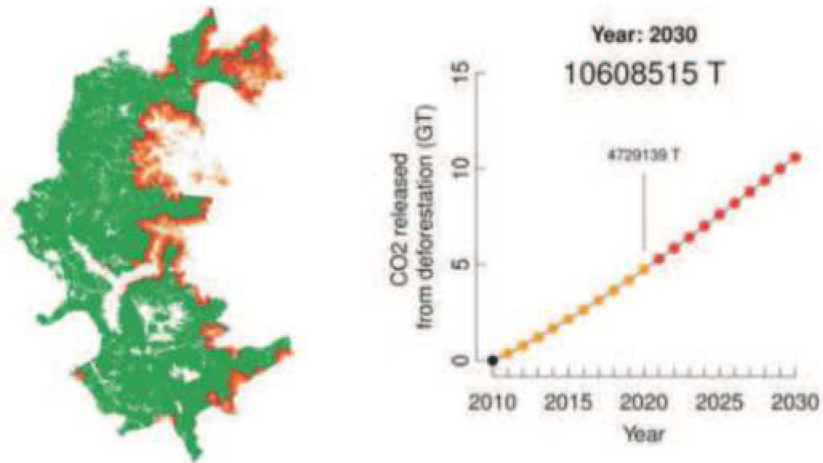


Figure 10: Projection de la déforestation et des émissions de carbone associée jusqu'en 2030 sur la région d'Andapa, nord de Madagascar. En orange la déforestation pour la période 2010-2020 et en rouge pour la période 2020-2030. Extrait de Vieilledent et al, 2012.

3 Objectifs et plan du manuscrit

3.1 Objectifs généraux et spécifiques

L'objectif de la thèse est d'**améliorer les estimations des émissions ou séquestrations de CO₂ associées à la déforestation, dégradation et régénération des terres à l'aide de méthodologies innovantes**. La finalité de cette thèse est i) de contribuer à une meilleure gestion des écosystèmes, par la fourniture d'informations spatiales justes, précises et utilisables à différentes échelles et ii) de pouvoir faire évoluer les outils et méthodes utilisées dans les projets, programme ou politiques REDD+.

Madagascar est pris comme exemple, et plus particulièrement la zone du sud-est (figure 12). Cette zone a été retenue pour son taux élevé de déforestation, son importante richesse en biodiversité, l'existence de zones de conservation de la forêt (Parcs Nationaux) et l'implémentation d'un projet REDD+ depuis 2009.

Comme mentionné ci-dessus, cette thèse suit l'approche proposée par le GIEC concernant la quantification des données d'activités et facteurs d'émissions, en vue de l'établissement de scénarios de référence. Suivant les décisions des COP concernant la REDD+ (section 1.2.1), un accent particulier a été donné sur le choix de méthodologies qui soient i) fiables, ii) à moindre coût, et iii) reproductibles. Cette thèse a été organisée en trois axes (figure 11) suivant les trois grandes sources d'incertitude présentées plus haut, et pour lesquels des objectifs thématiques (OTh) et techniques (OTe) ont été définis :

Suivi de la déforestation en région tropicale humide et sèche

- Développer une méthodologie fiable, précise et reproductible permettant le suivi de la déforestation de petites surfaces forestière sur de grandes superficies (OTe);
- Actualiser les chiffres de la déforestation sur la région des forêts humides à Madagascar (OTh);

Estimation des stocks de carbone dans le sol et leur évolution passée

- Élaborer des modèles de distribution de carbone organique dans les sols pour deux profondeurs de sols à partir des facteurs spatiaux de pédogénèse (OTe);
- Estimer les gains et pertes des stocks de carbone dans le sol à l'échelle des paysages et sur des étendues régionales (OTh);

Modélisation des scénarios de changement d'utilisation des terres

- Analyser les causes de la déforestation, dégradation des terres et régénération afin de mieux comprendre ces processus (OTe);

- Prédire des scénarios spatialisés de déforestation, dégradation des terres et régénération afin d'améliorer les outils d'aide à la décision et en particulier la planification territoriale (OTh);

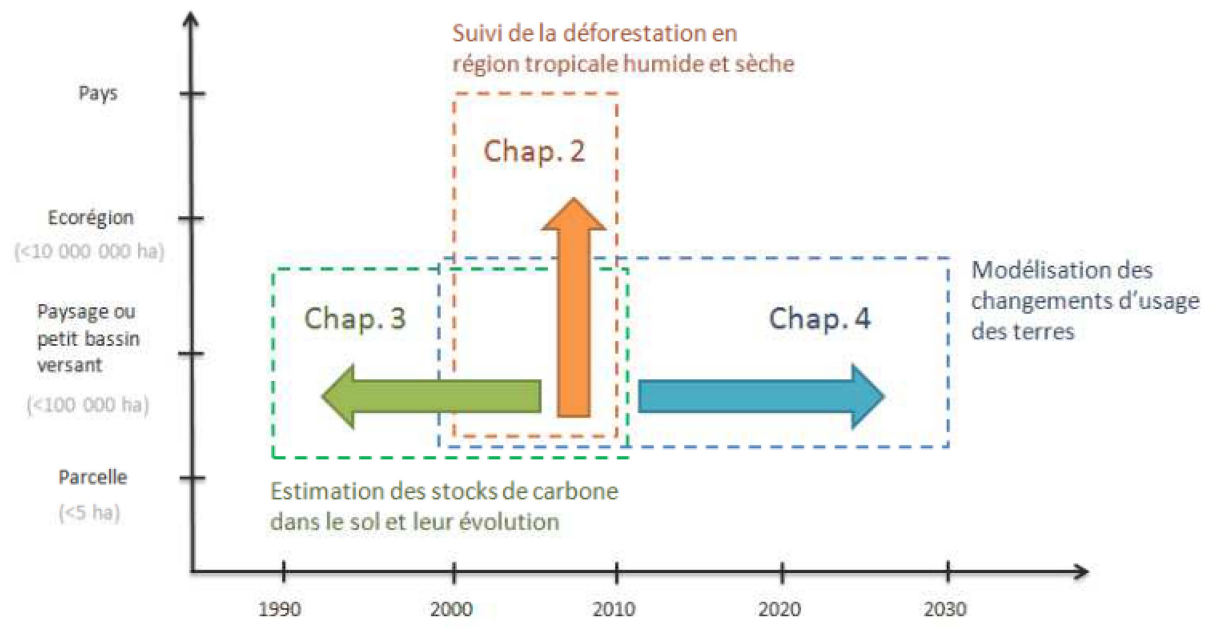


Figure 11: Illustration de l'organisation des thématiques de recherche abordées dans cette thèse

3.2 Zone d'étude

Madagascar est universellement reconnue pour son haut niveau d'endémisme, principalement localisées dans ses forêts (Goodman, 2005). Le pays a vu son couvert forestier diminuer dramatiquement depuis les 50 dernières années (Harper et al, 2007) pour des raisons multiples : l'agriculture itinérante, considérée comme la première des causes de déforestation mais aussi l'extension des zones de pâturages, la production de charbon, la coupe illégale de bois et l'exploration minière.

L'autre particularité de Madagascar est la grande diversité de ses climats (de aride à humide), de végétations (forêts épineuses, sèches, humides, mangroves) et de ses paysages (littoral, plaine, corridors escarpés, hautes terres). Afin d'atteindre nos objectifs spécifiques en termes d'échelle et en fonction des particularités des thématiques abordées, nous avons défini 3 périmètres d'étude (figure 11) pour les raisons suivantes :

Zone d'étude du chapitre 2. Cette zone a été définie selon les limites (région de référence) d'un projet pilote REDD+ : le Programme Holistique de Conservation des Forêts (PHCF).

Zone d'étude du chapitre 3. Cette zone a été définie à l'échelle régionale, centrée sur un espace de transition en région humide et sèche. La délimitation en rectangle suit les limites de disponibilité de certaines données spatiales (données de radiométrie gamma).

Zone d'étude du chapitre 4. Cette zone a été définie afin d'inclure les limites de deux aires protégées (le parc national d'Andohahela et le parc national de Midongy) et couvre également les limites d'intervention du PHCF.

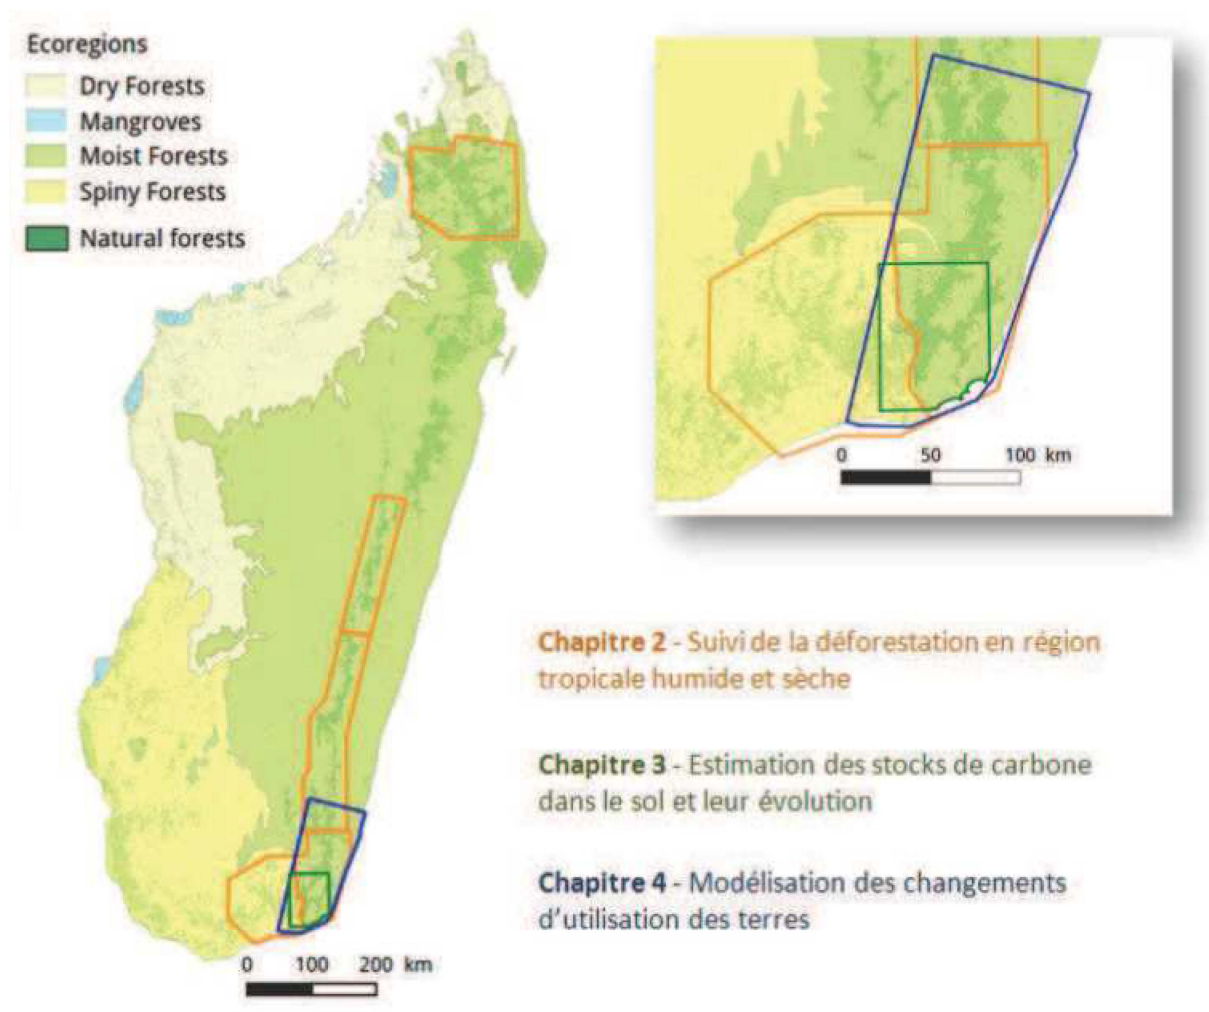


Figure 12: Carte de localisation des différentes zones d'étude en fonction des chapitres.

3.3 Plan du manuscrit

Les trois axes de cette thèse sont présentés dans les chapitres suivants :

Chapitre 2: Suivi de la déforestation en région tropicale humide, liée à l'agriculture itinérante sur pente

Ce chapitre s'intéresse aux dynamiques du territoire et aux changements d'usage de terres, plus particulièrement la déforestation. L'outil principal ici est le traitement des données satellites, qui permet de convertir de l'information physique (énergie captée par le satellite) en catégorie d'occupation du sol, et de faire leur suivi dans le temps. La disponibilité d'images permet aujourd'hui d'envisager un traitement de l'échelle locale à l'échelle nationale. L'enjeu principal réside dans notre capacité à quantifier précisément les petites surfaces de déforestation (parcelles de défriches brûlis sur pente) sur de grandes étendues.

Chapitre 3: Estimation des stocks de carbone dans le sol à l'échelle des paysages et détection des changements

Ce chapitre s'intéresse aux facteurs d'émission liés au sol, à travers la quantification des niveaux de stockage de carbone organique et leur évolution. Le couplage de données d'inventaire de sol et analyses en laboratoire avec des données environnementales spatialisées (issues des satellites d'observation de la terre) permettent de cartographier à des résolutions fines et sur de grandes étendues. L'enjeu principal soulevé ici est notre capacité à évaluer les changements de stock de carbone dans le passé sans connaissances de terrain.

Chapitre 4: Modélisation des changements d'utilisation des terres et analyse des facteurs de changements

Ce chapitre s'intéresse aux causes et facteurs de la déforestation, à la dégradation des terres et à la régénération, à partir d'une approche spatialisée. Cette connaissance est indispensable pour établir des scénarios, à l'aide de cartographie des risques ou d'opportunités. L'enjeu de cette étude est de pouvoir établir de modèle prédictif avec des précisions suffisantes afin d'en tirer des recommandations pertinentes pour les décideurs.

Un **chapitre de conclusion générale (Chapitre 5)** fait la synthèse des résultats obtenus, discute des avancées méthodologiques et des résultats obtenus au cours de ces travaux et propose différentes pistes de recherche et recommandations.

3.4 Mentions et note au lecteur

Le premier article présenté dans ce mémoire a été publié dans la revue *Remote Sensing of Environment* en 2013, le deuxième a été publié dans *International Journal of Applied Earth Observation and Geoinformation* en septembre 2016. Le troisième a été soumis à la revue *Landscape Ecology* en septembre 2016.

Il faut également noter qu'il s'agit d'une thèse sous Convention Industrielle de Formation par la Recherche (CIFRE), qui s'est inscrite dans un programme de recherche-action plus vaste, en collaboration avec différentes équipes de recherche et acteurs du développement territorial. Je suis intervenu (ou intervient toujours, à l'heure de remettre ce manuscrit) en tant que chargé de projets Recherche et Développement sur les trois projets suivants:

Projet PHCF : Programme Holistique de Conservation des Forêts à Madagascar mis en œuvre par Etc Terra, le World Wide Fund (WWF) et Agrisud International avec un financement de l'Agence Française de Développement (AFD) et Air France. Le projet est actuellement au cours d'une deuxième phase (2013-2017), après une première phase de quatre ans (2009-2013). <http://www.etcterra.org/fr/projets/phcf>

Projet BiosceneMada : « Scénarios de biodiversité sous l'effet conjoint du changement climatique et de la déforestation future à Madagascar », mise en œuvre par le CIRAD, la World Conservation Society (WCS), l'Office National de l'Environnement (ONE), et Etc Terra, financé par le Fond de Recherche pour la Biodiversité (FRB) et Fonds français pour l'environnement mondial (FFEM). Ce projet a démarré en 2014 et est en phase de capitalisation jusqu'en 2017. <http://bioscenemada.cirad.fr/>

Projet PERR FH : Programme Ecorégional REDD+ des forêts humides de Madagascar, projet mise en œuvre par Etc Terra, WCS, ONE, et Madagascar National Parks (MNP), financé par la Banque Mondiale dans le cadre du fond additionnel pour le Plan Environnemental 3 (PE3) de Madagascar. Ce projet s'est déroulé de février 2014 à mars 2015. <http://www.etcterra.org/fr/projets/perrfh>

D'autres études rédigées en tant que co-auteur et en lien avec le sujet de la thèse ont été publiées (Rakotomalala et al, 2015 ; Vieilledent et al, 2016; Clairotte et al, 2016) ou sont en cours de publication (Ramifehiarivo, et al, 2016).

L'article **Rakotomalala et al (2015)** est une extension de l'étude présentée dans le chapitre 2 qui vise à démontrer qu'il est possible d'utiliser la méthode à l'échelle nationale pour du suivi de la déforestation tout en actualisant les chiffres de la déforestation jusqu'en 2013.

L'article **Vieilledent et al (2016)** présente la première cartographie nationale des stocks de carbone forestiers à une résolution de 250 mètres à partir d'une approche similaire à celle présentée dans le chapitre 3. Une analyse prospective de l'évolution des stocks de carbone a été également réalisée.

L'article **Ramifehiarivo et al (2016)** présente les résultats de la cartographie numérique des stocks de carbone dans les sols à l'échelle nationale à partir de la méthode présentée dans le chapitre 3.

L'article **Clairotte et al (2016)** démontre qu'il est possible d'utiliser les outils de spectroscopie infra rouge pour la mesure et suivi du carbone organique du sol à l'échelle d'un pays, avec des précisions satisfaisantes et un coût réduit.

Ces quatres articles publiés sont présentés en Annexe.

4 Références du chapitre 1

- Achard, F., Beuchle, R., Mayaux, P., Stibig, H.-J., Bodart, C., Brink, A., Carboni, S., Desclée, B., Donnay, F., Eva, H. D., Lupi, A., Raši, R., Seliger, R. and Simonetti, D. 2014, Determination of tropical deforestation rates and related carbon losses from 1990 to 2010. *Glob Change Biol*, 20: 2540–2554. doi:10.1111/gcb.12605
- Aguilar-Amuchastegui N, Riveros JC, Forrest JL. 2014. Identifying areas of deforestation risk for REDD+ using a species modeling tool. *Carbon Balance and Management*, 9:10
- Avitabile, V., Herold, M., Heuvelink, G. B. M., Lewis, S. L., Phillips, O. L., Asner, G. P., Armston, J., Ashton, P. S., Banin, L., Bayol, N., Berry, N. J., Boeckx, P., de Jong, B. H. J., DeVries, B., Girardin, C. A. J., Kearsley, E., Lindsell, J. A., Lopez-Gonzalez, G., Lucas, R., Malhi, Y., Morel, A., Mitchard, E. T. A., Nagy, L., Qie, L., Quinones, M. J., Ryan, C. M., Ferry, S. J. W., Sunderland, T., Laurin, G. V., Gatti, R. C., Valentini, R., Verbeeck, H., Wijaya, A. and Willcock, S. (2016), An integrated pan-tropical biomass map using multiple reference datasets. *Glob Change Biol*, 22: 1406–1420. doi:10.1111/gcb.13139
- Asner GP, Clark JK , Mascaro J , Vaudry R, Chadwick KD , Vieilledent G , Rasamoelina M , Balaji A , Kennedy-Bowdoin T, Maatoug L, Colgan MS, Knapp DE. 2012. Human and environmental controls over aboveground carbon storage in Madagascar. *Carbon Balance Manag* 7(1):2. DOI: 10.1186/1750-0680-7-2
- Agarwal DK, Silander JA, Gelfand AE, Dewar RE, Mickelson JG. 2005. Tropical deforestation in Madagascar: analysis using hierarchical, spatially explicit, Bayesian regression models. *Ecological Modelling* 185 (2005) 105–131. doi:10.1016/j.ecolmodel.2004.11.023
- Baccini, A., S.J. Goetz, W. S. Walker, N. T. Laporte, M. Sun, D. Sulla-Menashe, J. Hackler, P.S. A. Beck, R. Dubayah, M. A. Friedl, et al. 2012. « Estimated Carbon Dioxide Emissions from Tropical Deforestation Improved by Carbon-Density Maps. » *Nature Climate Change* 2: 182–185.
- Bernoux, M., M. da Conceição Santana Carvalho, B. Volkoff, and C. C. Cerri. 2002. Brazil's Soil Carbon Stocks. *Soil Sci. Soc. Am. J.* 66:888-896. doi:10.2136/sssaj2002.8880
- Castella JC, Verbug PH. 2007. Combination of process-oriented and pattern-oriented models of land-use change in a mountain area of Vietnam. *Ecological modeling*, 202, 410-420

- Casse, T., Milhøj, A., Ranaivoson, S., Randriamanarivo, J.R., 2004. Causes of deforestation in southwestern Madagascar: what do we know? *Forest Policy and Economics* 6, 33–48. doi:10.1016/S1389-9341(02)00084-9
- Clairotte M, Grinand C. Kouakoua E, Thebault A, Saby N, Bernoux M, Barthès B. 2016. National calibration of soil organic carbon concentration using diffuse infrared reflectance spectroscopy. 276, 41-52, doi.org/10.1016/j.geoderma.2016.04.021
- DeFries R, Rudel T, Uriarte M. Hansen, M. 2010. Deforestation driven by urban population growth and agricultural trade in the twenty-first century. *Nature Geoscience* 3, 178 – 181. doi:10.1038/ngeo756
- De Sy V, Herold M, Achard F, Asner GP, Held A, Kelldorfer J, Verbesselt J. 2012. Synergies of multiple remote sensing data sources for REDD+ monitoring. *Current Opinion in Environmental Sustainability*, Volume 4, Issue 6, 696-706, ISSN 1877-3435, <http://dx.doi.org/10.1016/j.cosust.2012.09.013>.
- ER-PIN Madagascar, 2015. Emission Reductions Program Idea Note - Testing Emissions Reductions in the rainforest ecoregion. https://www.forestcarbonpartnership.org/sites/fcp/files/2015/September/MDG_ERPIN_English%20with%20annexes.pdf
- FAO, 2002 - TERRASTAT, Digital Soil Map of the World and Derived Soil Properties. Land and Water Development Division. Rome, Italie.
- Ferretti-Gallon K, Bush J. 2014. What Drives Deforestation and What Stops It? A Meta-Analysis of Spatially Explicit Econometric Studies. CGD Working Paper 361. Washington, DC: Center for Global Development. <http://www.cgdev.org/publication/what-drives-deforestation-and-what-stops-it-meta-analysis-spatially-explicit-econometric>
- FRA (Forest Ressource Assement), 2015. Global Forest Ressource Assement 2015. Food and Agriculture Organisation of the United State. ISBN 978-92-5-108826-5. 253 p.
- GBA (Secretariat of the Convention on Biological Diversity). 2014. Global Biodiversity Outlook 4 — Summary and Conclusions. Montréal, 20 pages
- GOFC-GOLD. 2015. A sourcebook of methods and procedures for monitoring and reporting anthropogenic greenhouse gas emissions and removals associated with deforestation, gains and losses of carbon stocks in forests remaining forests, and forestation. GOFC-GOLD Report version COP21-1, (GOFC-GOLD Land Cover Project Office, Wageningen University, The Netherlands).

- Gomez C, Viscarra Rossel RA, McBratney A. 2008. Soil organic carbon prediction by hyperspectral remote sensing and field vis-NIR spectroscopy: An Australian case study. *Geoderma*; 146, 403–411
- Goodman, S. M. & Benstead, J. P. Updated estimates of biotic diversity and endemism for Madagascar *Oryx*, 2005, 39, 73-77
- Gorenflo LJ , Corson C, Chomitz KM, Harper G, Honzák M, Özler B. 2010. Exploring the Association Between People and Deforestation in Madagascar. *Human Population*, 213, pp 197-221
- Grinand C, Rajaonarivo A, Bernoux M, Pajot V, Brossard M, Razafimbelo T, Albrecht A, Le Martret H (2009) Estimation des stocks de carbone dans les sols de Madagascar. *Étude et Gestion des Sols*, 16, 1, 23-33.
- IPBES. 2016. The methodological assessment report on scenarios and models of Biodiversity and Ecosystem Services. Intergovernmental Science-Policy Platform on Biodiversity and Ecosystem Services (IPBES). ISBN: 978-92-807-3570-3. Bonn, Germany,
- IPCC. 2006. IPCC guidelines for national greenhouse gas inventories. IGES, Japan, www.ipcc-nggip.iges.or.jp/public/2006gl/index.html.
- IPCC, 2014a. Climate Change 2014: The Physical Science Basis. Contribution of Working Group I to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change. Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA, 1132 pp
- IPCC, 2014b. Climate Change 2014: Impacts, Adaptation, and Vulnerability. Contribution of Working Group II to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change. Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA, 1132 pp
- Karsenty A. 2008. The architecture of proposed REDD schemes after Bali: facing critical choices. *International Forestry Review*, vol 10, 3, 2-25.
- Lagacherie P. 2008. Digital Soil Mapping : a state of the art. In *Digital soil mapping with limited data*. Ed. Hartemink, A and McBratney, A.B. and M.d.L. Mendonca-Santos. :3-181. [doi.org/ 10.1007/978-1-4020-8592-5](https://doi.org/10.1007/978-1-4020-8592-5)
- Le Maire, G, Marsden C, Nouvellon Y, Grinand C, Hakamada JS, Laclau JP (2011a) MODIS NDVI time-series allow the monitoring of Eucalyptus plantation biomass. *Remote Sensing of Environment*, 115, 10, 2624-2625

- Mas JF, Paegelow M, De Jong B, Masera O, Guerrero G, Follador M, Olguin M, Diaz JR, Castillo M.A., T. Garcia T. 2007. Modelling Tropical Deforestation: A Comparison of Approaches. 32nd symposium on remote sensing of environment, Jun 2007, San José, Costa Rica. 3 p. <halshs-01063568>
- Maxwell, S., Fuller, R., Brooks, T., Watson, J., 2016. Biodiversity: The ravages of guns, nets and bulldozers. *Nature* 536, 143. doi:10.1016/j.esd.2012.08.004
- MEA (Millennium Ecosystem Assessment). 2005. Ecosystems and Human Well-being: Synthesis. Island Press, Washington, DC, 155 pages
- Mitchard E.T.A , Saatchi S.S. , Baccini A., Asner G.P. , Goetz S.J., Harris N.L., Brown S. 2013. Uncertainty in the spatial distribution of tropical forest biomass: a comparison of pan-tropical maps. *Carbon Balance Manag.* 2013 Oct 26; 8 (1):10. doi: 10.1186/1750-0680-8-10.
- Minasny B, McBratney AB, Malone BP, Wheeler I. 2013. Digital Soil Mapping of Soil Carbon. *Advances in Agronomy*, 118. doi.org/10.1016/B978-0-12-405942-9.00001-
- Mulder V.L., de Bruin S., Schaepman M.E., Mayr T.R., 2011. The use of remote sensing in soil and terrain mapping — A review. *Geoderma*, Volume 162, Issues 1–2, 15 Pages 1-19, ISSN 0016-7061, <http://dx.doi.org/10.1016/j.geoderma.2010.12.018>.
- NRC (National Research Council). 2014. Advancing Land Change Modeling: Opportunities and Research Requirements. Washington DC, USA, ISBN 978-0-309-28833-0, 146 p.
- ONU (Organisation des Nations Unies), 1992, Déclaration de Rio sur l'environnement et le développement, Rio de Janeiro, 13 juin, A/CONF.151/26, vol. I.
- Prestele, R., Alexander, P., Rounsevell, M. D. A., Arneth, A., Calvin, K., Doelman, J., Eitelberg, D. A., Engström, K., Fujimori, S., Hasegawa, T., Havlik, P., Humpenöder, F., Jain, A. K., Krisztin, T., Kyle, P., Meiyappan, P., Popp, A., Sands, R. D., Schaldach, R., Schüngel, J., Stehfest, E., Tabeau, A., Van Meijl, H., Van Vliet, J. and Verburg, P. H. (2016), Hotspots of uncertainty in land-use and land-cover change projections: a global-scale model comparison. *Glob Change Biol.* doi:10.1111/gcb.13337
- Rakotomala F.A , Rabenandrasana, J. C. , Andriambahiny, J. E. 4 , Rajaonson R. , Andriamalala, F. ,Burren, C. , Rakotoarijaona J.R. , Parany, L. , Vaudry, R. , , Rakotoniaina,S. , Grinand, C. 2015. Estimation de la déforestation des forêts

humides à Madagascar entre 2005, 2010 et 2013. *Revue Française de Télédétection et Photogrammétrie*, 211-212, 11-23

R-PIN Madagascar, 2008. REDD+ Readiness Project Idea Note – Madagascar. https://www.forestcarbonpartnership.org/sites/forestcarbonpartnership.org/files/Madagascar_FCPF_R-PIN.pdf

R-PP Madagascar, 2014. REDD+ Readiness Preparation Prosal – Madagascar. <https://www.forestcarbonpartnership.org/sites/fcp/files/2014/August/R-PP%20June%202014.pdf>

Saatchi SS, Harris NL, Brown S, Lefsky M, Mitchard ETA, Salas W, Zutta BR, Buermann W, Lewis SL, Hagen S, et al. 2011. Benchmark map of forest carbon stocks in tropical regions across three continents. *Proc Natl Acad Sci*, 108:9899–9904.

Shoch D., Eaton J., Settelmyer S. 2013. Project Developer's Guidebook to VCS REDD Methodologies. Version 2. Conservation International, Washington. 97p.

Simonet, G.; Karsenty, A.; Newton, P.; de Perthuis, C.; Schaap, B. & Seyller, C. (2015a), 'REDD+projects in 2014: an overview based on a new database and typology', *Cahiers de la ChaireEconomie du Climat - Information and Debates Series 32*. Working Paper.

Vagen TG, Winowiecki LA (2013) Mapping of soil organic carbon stocks for spatially explicit assessments of climate change mitigation potential. *Environ. Res. Lett.* 8. 1-9, doi:10.1088/1748-9326/8/1/015011

Veldkamp A, Lambin EF, 2001. Predicting land-use change. *Agriculture, Ecosystems and Environment*, 85, 1–6

Vieilledent, G., Grinand, C., Vaudry, R., 2013. Forecasting deforestation and carbon emissions in tropical developing countries facing demographic expansion: a case study in Madagascar. *Ecology and Evolution* 3, 1702–1716. doi:10.1002/ece3.550

Vieilledent G, Gardi O, Grinand C, Burren C, Andriamananjato M, Camara C, Gardner CJ, Glass L, Rasolohery A, Ratsimba H, Gond V, Rakotoarijaona J. 2016. Bioclimatic envelope models predict a decrease in tropical forest carbon stocks with climate change in Madagascar. *Journal of Ecology*, 104: 703-715.

Chapitre 2 - Suivi de la déforestation en région tropicale

1	CONTEXTE DE L'ÉTUDE	44
1.1	CHALLENGES.....	44
1.2	INNOVATIONS	45
1.3	PROBLÉMATIQUES SCIENTIFIQUES	45
2	ESTIMATING DEFORESTATION IN TROPICAL HUMID AND DRY FORESTS IN MADAGASCAR FROM 2000 TO 2010 USING MULTI-DATE LANDSAT SATELLITE IMAGES AND THE RANDOM FORESTS CLASSIFIER	46
2.1	RÉSUMÉ	47
2.2	ABSTRACT	48
2.3	INTRODUCTION	49
2.3.1	<i>Techniques for estimating deforestation over large forest areas</i>	<i>49</i>
2.3.2	<i>Classification algorithms</i>	<i>50</i>
2.3.3	<i>Accuracy assessment of land cover change</i>	<i>51</i>
2.3.4	<i>Objectives.....</i>	<i>51</i>
2.4	MATERIAL AND METHOD.....	53
2.4.1	<i>Study area</i>	<i>53</i>
2.4.2	<i>Landsat image collection and pre-processing</i>	<i>54</i>
2.4.3	<i>Classification of land cover change</i>	<i>56</i>
2.4.4	<i>Post processing</i>	<i>59</i>
2.4.5	<i>Estimating deforestation rates</i>	<i>60</i>
2.4.6	<i>Accuracy Assessment</i>	<i>61</i>
2.4.7	<i>Transparency and repeatability of the method.....</i>	<i>63</i>
2.5	RESULTS.....	64
2.5.1	<i>Sampling intensity and importance of the variables.....</i>	<i>64</i>
2.5.2	<i>Accuracy assessment</i>	<i>66</i>
2.5.3	<i>Analyses of deforestation estimates and trends.....</i>	<i>68</i>
2.6	DISCUSSION AND CONCLUSION	70
2.6.1	<i>The accuracy of the method.....</i>	<i>70</i>
2.6.2	<i>Comparison with other annual deforestation rate estimates</i>	<i>71</i>
2.6.3	<i>On the methodology</i>	<i>71</i>
2.6.4	<i>On the forest monitoring perspectives.....</i>	<i>73</i>
2.7	ACKNOWLEDGMENT	75
3	CONCLUSION DE L'ÉTUDE	76
4	REFERENCES DU CHAPITRE 2	77

“One of the challenges confronting the remote sensing research community is to develop an improved understanding of the change detection process on which to build an understanding of how to match applications and change detection methods”

(Coppin et al, 2004)

"The best processing tool is the eye and our brain"

(Anonyme)

1 Contexte de l'étude

1.1 Challenges

Madagascar est universellement reconnu pour son haut niveau d'endémisme, principalement dans ses forêts (Goodman, 2005). Madagascar a vu son couvert forestier diminuer dramatiquement depuis les 50 dernières années (Harper et al, 2007) pour des raisons multiples : l'agriculture itinérante, considérée comme la première des causes de déforestation mais aussi l'extension des zones de pâturages, la production de charbon, la coupe illégale de bois et l'exploration minière. Face à l'enjeu de maintien d'une biodiversité exceptionnelle et des services rendus par cette biodiversité (stockage de carbone, provision d'eau potable et pour l'agriculture, contrôle de l'érosion, fourniture de produits ligneux et non ligneux) plusieurs études de cartographie de la déforestation ont été réalisées à l'échelle nationale, pour les périodes 1950-1970-1990-2000 (Harper et al 2007) et pour les années 1990-2000-2005 (MEFT et al 2009). Ces études montrent cependant certaines limites : elles ne tiennent pas compte de la définition de la forêt nationale, nécessaire pour alimenter les discussions sur la REDD+, sont marquées par des surfaces importantes sous nuage et montrent des incohérences à des échelles locales. Sans remettre en cause la valeur de ces travaux, notamment à l'échelle nationale et à des fins de sensibilisation, plusieurs aspects méthodologiques expliquent les limites de ces cartographies. La méthode utilisée dans ces deux études consiste à produire des cartes forestières pour chaque année d'étude, puis à les soustraire pour identifier les zones de changements. Il a été rapporté que cette technique engendrait une multiplication des erreurs contenues dans les deux cartes (GOFC-GOLD, chap. 2.6, 2010), augmentant le nombre de fausses détections des zones de changement (erreurs d'omissions ou commissions). Deuxièmement, les unités minimales de cartographie (UMC) appliquées sur ces cartes sont de un hectare, une superficie trop vaste pour détecter la pratique d'agriculture itinérante à Madagascar. En effet, en région humide, les défrichements ont lieu principalement sur des pentes moyennes à fortes et s'étendent sur des parcelles de quelques dizaines de mètres de cotés. Le seuil de l'UMC doit donc être diminué si l'on veut éviter de sous-estimer la déforestation. Enfin, la validation des cartes n'a pas été réalisée sur des bases statistiques et bonnes pratiques actuelles de validation des cartes forestières ce qui ne permet pas de se fier aux indicateurs de qualité.

1.2 Innovations

Dans cette étude nous proposons plusieurs innovations :

- Utilisation de techniques avancées de télédétection utilisant la combinaison multi-date d'image satellites Landsat et de l'algorithme random Forest. Cet algorithme a montré de bonnes capacités prédictives dans de nombreux domaines mais n'avait jamais été utilisé dans le cadre de la détection de changement d'occupation du sol;
- Mise à jour des chiffres de la déforestation de 2000 à 2010, alors que la dernière estimation remontait à 2005 et en se basant sur la définition officielle de la forêt;
- Mise en place d'une procédure de validation statistique satisfaisante incluant un effort conséquent de photo-interprétation (30 000 points d'observation de référence);
- Utilisation d'outils libres et de données facilement accessibles afin d'augmenter la transparence et la reproductibilité de la méthode.

1.3 Problématiques scientifiques

À travers cette étude, on cherche à répondre aux trois questions suivantes:

- Quelles sont les tendances récentes de la déforestation à Madagascar à l'échelle régionale ?
- Peut-on suivre la déforestation liée à la pratique de défriche-brûlis sur de petites parcelles avec précision ?
- Le cas échéant, quelles sont les modalités pour un changement d'échelle, du régional au national ?

2 Estimating deforestation in tropical humid and dry forests in Madagascar from 2000 to 2010 using multi-date Landsat satellite images and the Random Forests classifier

Article published in Remote Sensing in Environment

Grinand, C.^{1,2,3}, Rakotomalala, F.^{3,4}, Gond, V.⁵, Vaudry, R.³, Bernoux, M.⁷, Vieilledent, G.^{5,6}

¹ ETC Terra, 127 rue d'Avron, 75020, Paris, France

² ED SIBAGHE, Montpellier SupAgro, 2 Place Viala, 34060 Montpellier Cedex 2

³ ETC Terra-Madagascar, Lot VE 26 L, Ambanidia, 101 Antananarivo, Madagascar

⁴ IOGA, Institut et Observatoire de Géophysique d'Antananarivo, BP 3843, 101 Antananarivo, Madagascar

⁵ Cirad, UPR BSEF, F-34398 Montpellier, France

⁶ Cirad-Madagascar, DP Forêt et Biodiversité, 101 Antananarivo, Madagascar

⁷ IRD, Eco&Sols, 2 Place Viala, F-34060 Montpellier, France

* Contact author: c.grinand@etcterra.org

2.1 Résumé

Des cartographies de la déforestation à haute résolution et haute précision couvrant des étendues spatiales importantes dans les pays tropicaux sont nécessaires pour la planification de la conservation de la forêt et pour des programmes tels que REDD+ (Réduction des Emissions liées à Déforestation et Dégradation de la Forêt). A partir de logiciels open source (R, Grass et QGis) et une approche statistique innovante combinant des données satellites multi-date et l'algorithme random Forest, nous avons obtenu une cartographie de la déforestation pour les périodes 2000-2005 et 2005-2010, avec une unité minimum de cartographie de 0,36 ha, et couvrant 7,7 millions d'hectares, c.à.d. 40,3% des forêts humides et 20,6% des forêts sèches de Madagascar. L'incertitude des cartes de déforestation ont été calculées en comparant les résultats de la classification avec plus de 30 000 observations visuelles sur la base d'une grille régulière de point. Nous avons évalué la précision sur la base des pixels (matrice de confusion) et en mesurant les différences entre les résultats obtenus par cette méthode « wall-to-wall » et par échantillonnage de points. A l'échelle du pixel, la précision utilisateur était de 84,7% pour les occupations du sol stables et 60,7% pour les zones de changements. En moyenne pour l'ensemble de la zone d'étude, nous avons obtenus une différence relative de 2% pour les occupations du sol stable et 21,1% pour les zones de changements, entre les deux approches. En fonction de la zone d'étude, nos estimations conservatrices de la déforestation annuelle vont de 0,93 à 2,33%.an⁻¹ pour les forêts humides et de 0,46 à 1.17%.an⁻¹ pour les forêts sèches. Dans cette étude, nous décrivons une approche de cartographie de la déforestation avec des niveaux d'incertitude satisfaisante et qui peut être transposée à d'autres régions tropicales.

Key words:

Deforestation

Détection des changements

Classification de l'occupation du sol

Landsat TM,

Machine Learning

Madagascar

Random Forests

REDD+

2.2 Abstract

High resolution and low uncertainty deforestation maps covering large spatial areas in tropical countries are needed to plan efficient forest conservation and management programmes such as REDD+ (Reducing Emissions from Deforestation and Forest Degradation). Using open-source free software (R, GRASS and QGis) and an original statistical approach combining multi-date land-cover observations based on Landsat satellite images and the Random Forests classifier, we obtained up-to-date deforestation maps for the periods 2000-2005 and 2005-2010 with a minimum mapping unit of 0.36 ha for 7.7 M hectares, i.e. 40.3% of the tropical humid forest and 20.6% of the tropical dry forest in Madagascar. Uncertainty in deforestation on the maps was calculated by comparing the results of the classification to more than 30,000 visual interpretation points on a regular grid. We assessed accuracy on a per-pixel basis (confusion matrix) and by measuring the relative surface difference between wall-to-wall approach and point sampling. At the pixel level, user accuracy was 84.7% for stable land cover and 60.7% for land cover change. On average for the whole study area, we obtained a relative difference of 2% for stable land cover categories and 21.1% land cover change categories respectively between the wall-to-wall and the point sampling approach. Depending on the study area, our conservative assessment of annual deforestation rates ranged from 0.93 to 2.33 %.yr-1 for the humid forest and from 0.46 to 1.17 %.yr-1 for the dry forest. Here we describe an approach to obtain deforestation maps with reliable uncertainty estimates that can be transposed to other regions in the tropical world.

Key words:

Deforestation

Change Detection

Classification of Land Cover

Landsat TM,

Machine Learning

Madagascar

Random Forests

REDD+

2.3 INTRODUCTION

Assessing changes in tropical forest cover is a challenging research and operational topic that addresses issues like climate change, biodiversity conservation and sustainable ecosystem management. Global net loss of forest area has been estimated at 5.2 million hectares per year between 2000 and 2010 (FRA, 2010) and, according to the most recent studies (Harris et al., 2012; Baccini et al., 2012), is responsible for 10% to 25% of anthropogenic greenhouse gas (GHG) emissions to the atmosphere. Tropical deforestation is a major contributor to GHG emissions because of the extent of forest being cleared each year and because of the high carbon stock per unit area (Achard et al., 2010). The REDD+ mechanism (Reducing Emissions from Deforestation and Forest Degradation) in the United Nations Framework Convention on Climate Change (UNFCCC) aims to encourage developing countries to slow down deforestation through a compensation mechanism. This mechanism requires accurate, transparent, and cost-effective GHG measurement and monitoring systems (Olander et al., 2008). Despite well established guidelines provided by the international scientific community (IPCC, 2006; GOFC-GOLD, 2010), improvements in remote sensing techniques and data availability are still necessary to provide more accurate and cost-effective estimates of forest change.

2.3.1 Techniques for estimating deforestation over large forest areas

Recent reviews of methods used to estimate deforestation highlight two different methods of monitoring large areas of forest: the exhaustive mapping of forest extent (also known as the “wall-to-wall” approach) or point sampling (Achard et al., 2010; Hansen and Loveland, 2012, GOFC-GOLD, 2010). The wall-to-wall approach uses satellite images (such as Landsat (Harper et al., 2007; Gutman et al., 2005), AVHRR (De Fries et al., 2002), MODIS (Freidl et al., 2002) or MERIS (Bicheron et al., 2008)) to map the full extent of forest and changes in forest area through hybrid techniques that combine automated digital segmentation and/or classification with visual interpretation (GOFC-GOLD, 2011, Rasi et al., 2012) or fully automated techniques (Hansen et al., 2008, Huang et al., 2009, Potapov et al., 2012). Point sampling approach consists in identifying partial but representative land cover observations through ground surveys or through visual interpretation of satellite images to estimate forest and deforestation extent over the entire area (Steininger et al., 2009; Rasi et al., 2012).

Point sampling reduces the operational cost of exhaustive analysis of a large number of satellite images, while improving the thematic accuracy of (for example) regrowth or degradation assessment by focusing on small areas (Achard, et al., 2002, Duveiller et al., 2008, Stach et al., 2009, FRA, 2010, Rasi et al., 2011). However, the accuracy of point sampling is closely linked to the quality of the sampling design (Steininger et al., 2009) and

does not enable the production of deforestation maps of the entire forest area. Such maps are however required to target conservation efforts and to allow consistent spatial analysis of deforestation (Vieilledent et al. 2013).

Classical wall-to-wall land cover change analysis implies pairwise image comparison. This method of detecting change has been widely used (Harper et al., 2007, Stach et al., 2009) and provides useful transition matrices describing change from one land category at date 1 to another land category at date 2 (Huang et al., 2009; Duveiller et al., 2008). But when two single date maps are used in combination to derive land cover change, individual errors will be multiplied if errors on the two maps are assumed to be independent (Fuller et al., 2003). This seriously undermines the accurate detection of subtle change in forest area, and it is consequently recommended to combine satellite images acquired at many different dates in a single analysis that identifies change directly (GOFC-GOLD, chap. 2.6, 2010). In other words, supervised classification is performed on stacked images acquired at many different dates. This technique allows seasonal variations and vegetation dynamics to be taken into account (Pennec et al., 2011). For instance, slash-and-burn plots may subsequently have a different cover (a permanent crop, fallow, secondary regrowth) and secondary forest, forested fallow and intact forest may be confused depending on the selected date. Thus, increasing the number of dates using time series of satellite images reduces the uncertainty associated with land cover change classification.

2.3.2 Classification algorithms

Open access to the 20-year Landsat archive (called the Landsat Global Land Survey Program) has greatly reduced the cost and facilitated the processing of large time series for the estimation of land cover change (Hansen and Loveland, 2012). Given that multi-date satellite images are needed to reduce the uncertainty associated with land cover change classification, the usual parametric classification algorithms (such as classification by maximum likelihood) may not be appropriate for the classification of combined multi-date images because of the heterogeneous spectral signature of land cover categories over large areas. To overcome this problem, data mining and machine learning techniques (including neural networks, decision trees, support vector machines and ensemble classifiers) have recently emerged in remote sensing, making it possible to deal with complex land cover status and dynamics. Such algorithms are efficient because they do not rely on the data distribution assumption (e.g. normality), are able to handle noisy observation (Breiman et al., 20010), and can be efficiently applied to large complex datasets if supported by sufficient training data (Rodriguez-Galiano et al., 2012). Among these algorithms, the Random Forests (RF) classifier has already provided interesting results in several studies using satellite images. For instance, Schneider (2012) reported that RF outperformed maximum likelihood classifier and

was better than a support vector machine classification based on accuracy assessment and visual interpretation of the resulting maps. Previous RF applications include land cover classification using Modis data (Clark et al., 2010, Aide et al., 2012), Landsat data (Gislason et al., 2006; Lawrence et al., 2004, Rodriguez-Galiano et al., 2012, Schneider, 2012) or hyperspectral data (Ham et al., 2005), digital soil mapping (Grimm et al., 2008) and forest biomass mapping (Baccini et al., 2012).

2.3.3 Accuracy assessment of land cover change

Accuracy assessment must be associated with deforestation maps, as some authors consider errors in land cover change to be the main source of error in estimates of GHG emissions (Pelletier et al., 2011; Harris et al., 2012). A common approach for accuracy assessment implies computing an error matrix from independent ground survey observations or from visual interpretation of high resolution images to quantify class specific accuracies and overall map accuracy. A probability based sampling design is required for the accurate error estimation of land change categories (Stehman, 2009). Assessing a land cover map is known to be difficult, but assessing land cover change maps is even more challenging (Hansen and Loveland, 2012) mainly due to the difficulty in obtaining accurate land cover change reference datasets (Foody, 2010). Field surveys of historical change are tricky since they involve questioning people with a deep knowledge of the plot's history (e.g. the landowner). Ground truth observation via remote sensing is also constrained by the availability and resolution of the images. Another problem with change detection assessment is the extent of the change. Fuller et al., (2003) estimate that "small to medium scale changes requires levels of precision in mapping which are near impossible to achieve [...] unless it (the survey) is tailor made and rigorously applied to the recording of change". For all these reasons, accurate assessment of land cover change is not a trivial task and requires particular attention.

2.3.4 Objectives

Madagascar is universally recognized for its high level of biodiversity and endemism (Goodman 2005). The biodiversity is mainly located in its tropical forests. In the last 50 years, Madagascar has experienced a dramatic loss of forest (Harper, et al., 2007) due to traditional slash and burn, pasture extension, charcoal production, illegal logging of precious wood, and mining activities, with consequences for both biodiversity conservation and GHG emissions. To curb deforestation, Madagascar is highly committed to the implementation of the REDD+ programme through both the development of REDD+ pilot projects at regional scale and policy decisions at national scale. Previous work on land cover and land cover change mapping has provided valuable insight into vegetation status (Mayaux et al., 2000, Mayaux et al., 2004, Moat and Smith, 2007) and dynamics (Harper et al., 2007). However these insights

cannot be used directly since the definition of forest varies widely among studies and does not provide sufficient levels of information (a resolution of 1 km or a minimum mapping unit of 2 ha) for the detection of subtle change. Using Madagascar as a case study, we first used the RF algorithm to map land cover change using a 10-year time series of Landsat TM satellite images covering large forest areas. Second, we calculated up-to-date annual deforestation rates for the period 2000 to 2010, and third, we assessed the accuracy of forest cover change using more than 30,000 visual interpretation points on a regular grid. The specific aim of this study was to develop a transparent and cost-effective methodology to obtain reliable deforestation maps associated with uncertainty estimates that can be easily transposed to other regions in the tropical world prone to subsistence agriculture.

2.4 MATERIAL AND METHOD

2.4.1 Study area

The study area was divided into five separate forest zones in Madagascar (figure 14) covering a total area of 7.7 million hectares. According to the most recent vegetation map (Moat and Smith, 2007), the study areas include 2,407,000 ha of tropical forest divided into 372,000 ha of spiny-dry forest (with precipitation < 1000 mm.yr-1) and 2,035,000 ha of humid forest (with precipitation > 1000 mm.yr-1) in 2005. Except for the dry region, all these sites are located in hilly areas with medium to steep slopes, which is the only remaining typical intact humid forest landscape in Madagascar. Slash and burn and shifting cultivation are among the main agricultural practices found everywhere.

Each of the study areas – or reference areas in the REDD+ jargon - encompasses project sites of a REDD+ pilot programme called Holistic Programme for Conservation of Forests in Madagascar (figure 14). The study areas were manually delineated using local knowledge in order to include a large forested area with homogeneous bio-physical conditions (e.g. climate or topographic range), similar to those of the project sites. The project sites cover more than 500 000 ha of forest out of a total of 850 000 ha concerned by the creation of new protected areas, forest restoration and promotion of sustainable agriculture as an alternative to slash-and-burn practices. The extent, the project sites and the study areas, were used to produce estimates of deforestation rates.

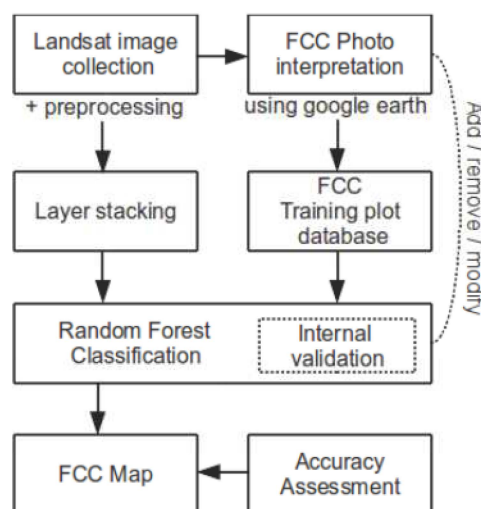


Figure 13 : Flow diagram of the processing steps. FCC stands for Forest Cover Change.

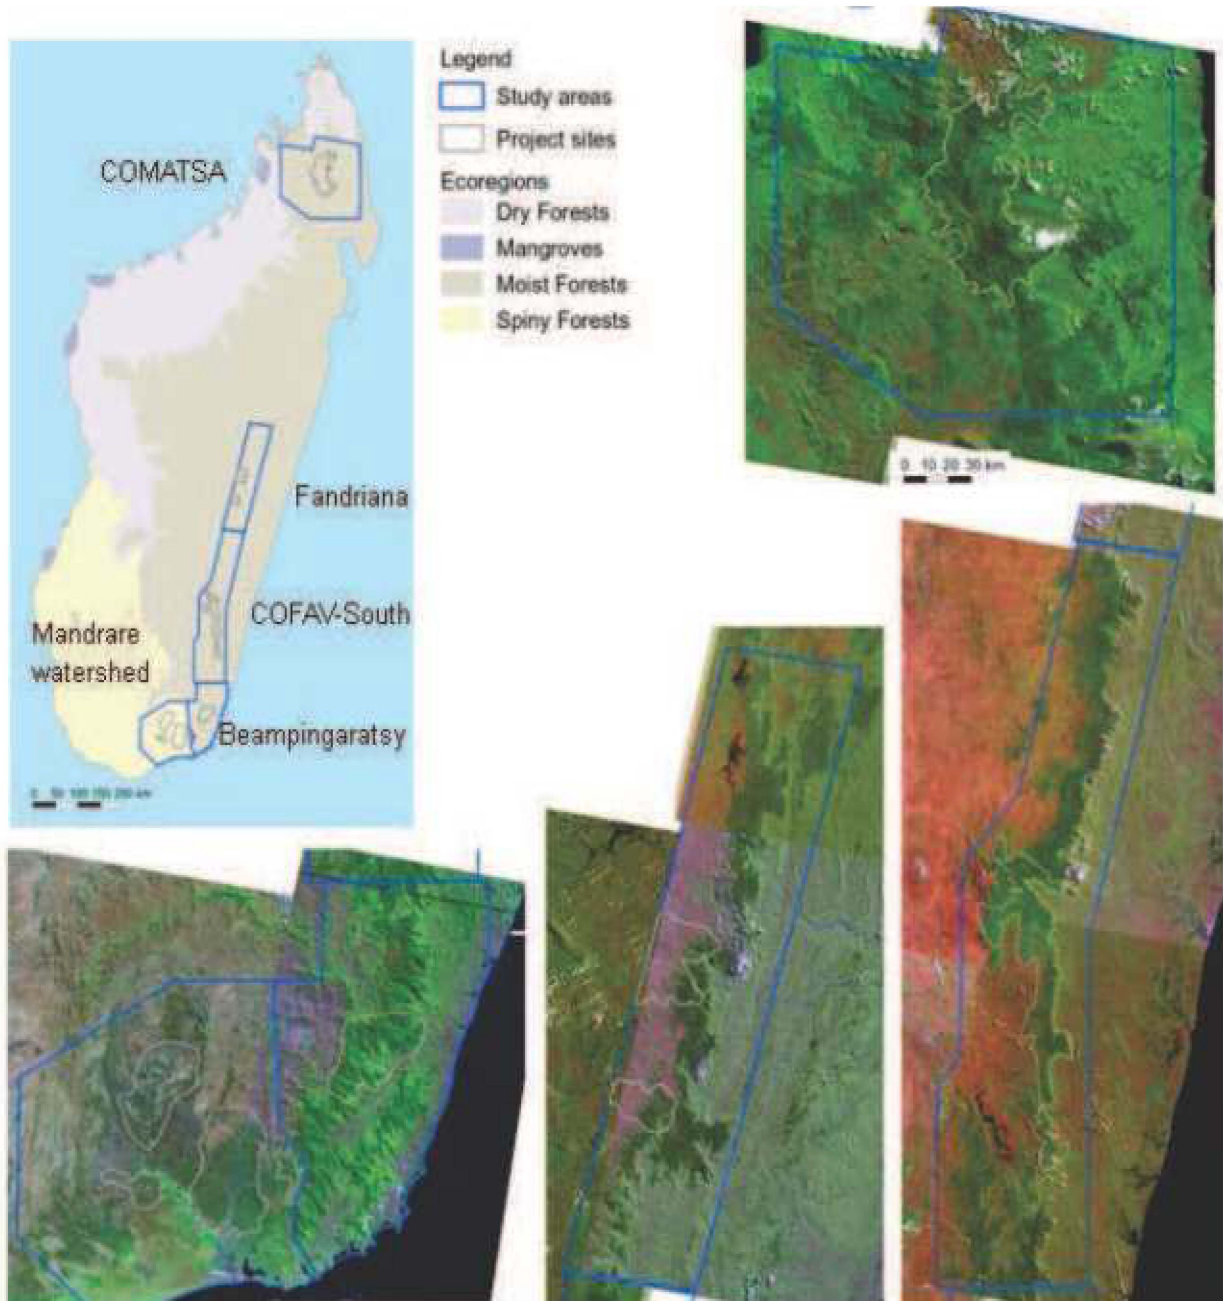


Figure 14: Location of the study areas and project sites in Madagascar. Background satellite images are Landsat 5 from circa 2005 in a false colour composite display, RGB=542. The source of the eco-region map is the Global 200 World Wide Fund project (http://en.wikipedia.org/wiki/Global_200).

2.4.2 Landsat image collection and pre-processing

The steps of the procedure are summarized in figure 13. Multi-temporal studies require the use of geometrically consistent images. Standard orthorectified Landsat image databases are available for the years 1975, 1990, 2000 worldwide (Tucker et al., 2004). Unfortunately, in our study area, the GLS 2005 Landsat product (Gutman et al, 2005) were mainly based upon

Landsat 7 which has high rates of no data values (stripping) due to its failure in 2003. For this reason, Landsat TM images were collected for reference dates in 2005 and 2010. We selected images with the lowest cloud cover and which were available in a time frame of plus or minus one year compared to the reference date. These criteria were met for every site except the northern site, which had a large permanent cloud cover. For this particular site, we looked for suitable images from 1990. From the USGS EROS portal, level 1 terrain corrected (L1T) images for 2005 and 2010 were downloaded and all images were visually inspected for geometric precision based on the GLS 2000 image. The data showed a good overall geometric precision with less than 1 pixel offset compared with the 2000 image. Radiometric normalization was not performed, since this step is not required when images are analysed simultaneously rather than individually (Song et al., 2001 cited in Schneider, 2012) and because decision tree algorithms can handle variables on a relative scale. We produced mosaic images for each date and each site by simple overlay, with the least cloudy image at the top of the mosaic. Finally, we derived a normalized difference vegetation index (NDVI) and a normalized infra red index (NIRI) from the mosaic images to obtain an enhanced auxiliary dataset. The Landsat image database processed in this study is presented in tableau 3.

Tableau 3 : *Landsat image database used in this study.*

Region	Ref. scene	Date ~2000	Date ~2005	Date ~2010
COMATSA	158-070	22/08/1996	14/05/2006	08/09/2008
	159-070	29/06/1990	31/05/2004	30/04/2010
Fandriana	158-073	29/09/2001	24/03/2005	30/09/2009
	158-074	28/10/2000	25/04/2005	17/11/2010
	159-074	29/04/2001	10/01/2005	30/04/2010
COFAV-South	158-075	22/04/2001	03/08/2005	17/11/2010
	159-075	29/04/2001	09/12/2005	30/04/2010
	158-076	22/04/2001	03/08/2005	17/11/2010
	159-076	29/04/2001	10/01/2005	08/11/2010
Beampingaratsy	158-077	13/09/2001	25/04/2005	17/11/2010
	159-077	28/05/2000	06/08/2006	11/01/2011
Mandrare	158-077	13/09/2001	25/04/2005	17/11/2010
	159-077	28/05/2000	06/08/2006	11/01/2011

2.4.3 Classification of land cover change

.2.4.3.1 Collection of training plot data

Accurate training plot data are essential for supervised classification. Several studies have shown that non-parametric machine learning algorithms, such as Random Forests, need a larger number of training data to attain optimal results (Potapov et al., 2012, Rodriguez-Galiano et al., 2012, Schneider, 2012). We conducted a free selection of training plots to obtain the most representative coverage of land cover and land cover change either in the number of features or spatial distribution. Visual interpretation of many small subsets of images was performed where a cluster of polygons representing the diversity of land cover, and land cover change was delineated in this particular area. By experience, we found that a scale of 1:10000 was suitable to distinguish shifting cultivation cropland in a sufficiently large portion of the landscape. A subset of images corresponds approximately to what a photo interpreter can see in the screen display at a scale of 1:10000. An example of visual interpretation of cluster of training plot is presented in figure 15. Additional sources of information, including freely available QuickBird images from Google Earth and expert knowledge were used as reference material to help interpretation. We used six land cover categories (humid forest, dry forest, cropland-savannah, wetland, rock-bare soil, cloud and shadow) which were observed for each date. For each land cover, a minimum of 20 training plots were targeted. Next, we aggregated the observation into one single forest cover change nomenclature, including six land cover categories over the 2000-2010 period and four land cover change categories (deforestation of humid and dry forest for both monitoring periods). For land cover change categories, efforts were made to capture the entire extent of the deforestation patches, contrary to land cover categories for which random or odd shapes were used. Specific rules were applied to reduce the extent of clouds and shadows. For instance, a plot observed to be forested at date 1, cloudy at date 2, and forested at date 3 was considered to be forested throughout the historical period. Although we were easily able to deduce the fate of forest or non-forest area in many cases, this was not possible in all cases. For instance, a cloud-shadow classification was used when cloud or shadow was observed at date 2, while forest was observed at date 1 and non-forest at date 3. This method enabled us to reduce the extent of clouds and shadows without entirely suppressing them.

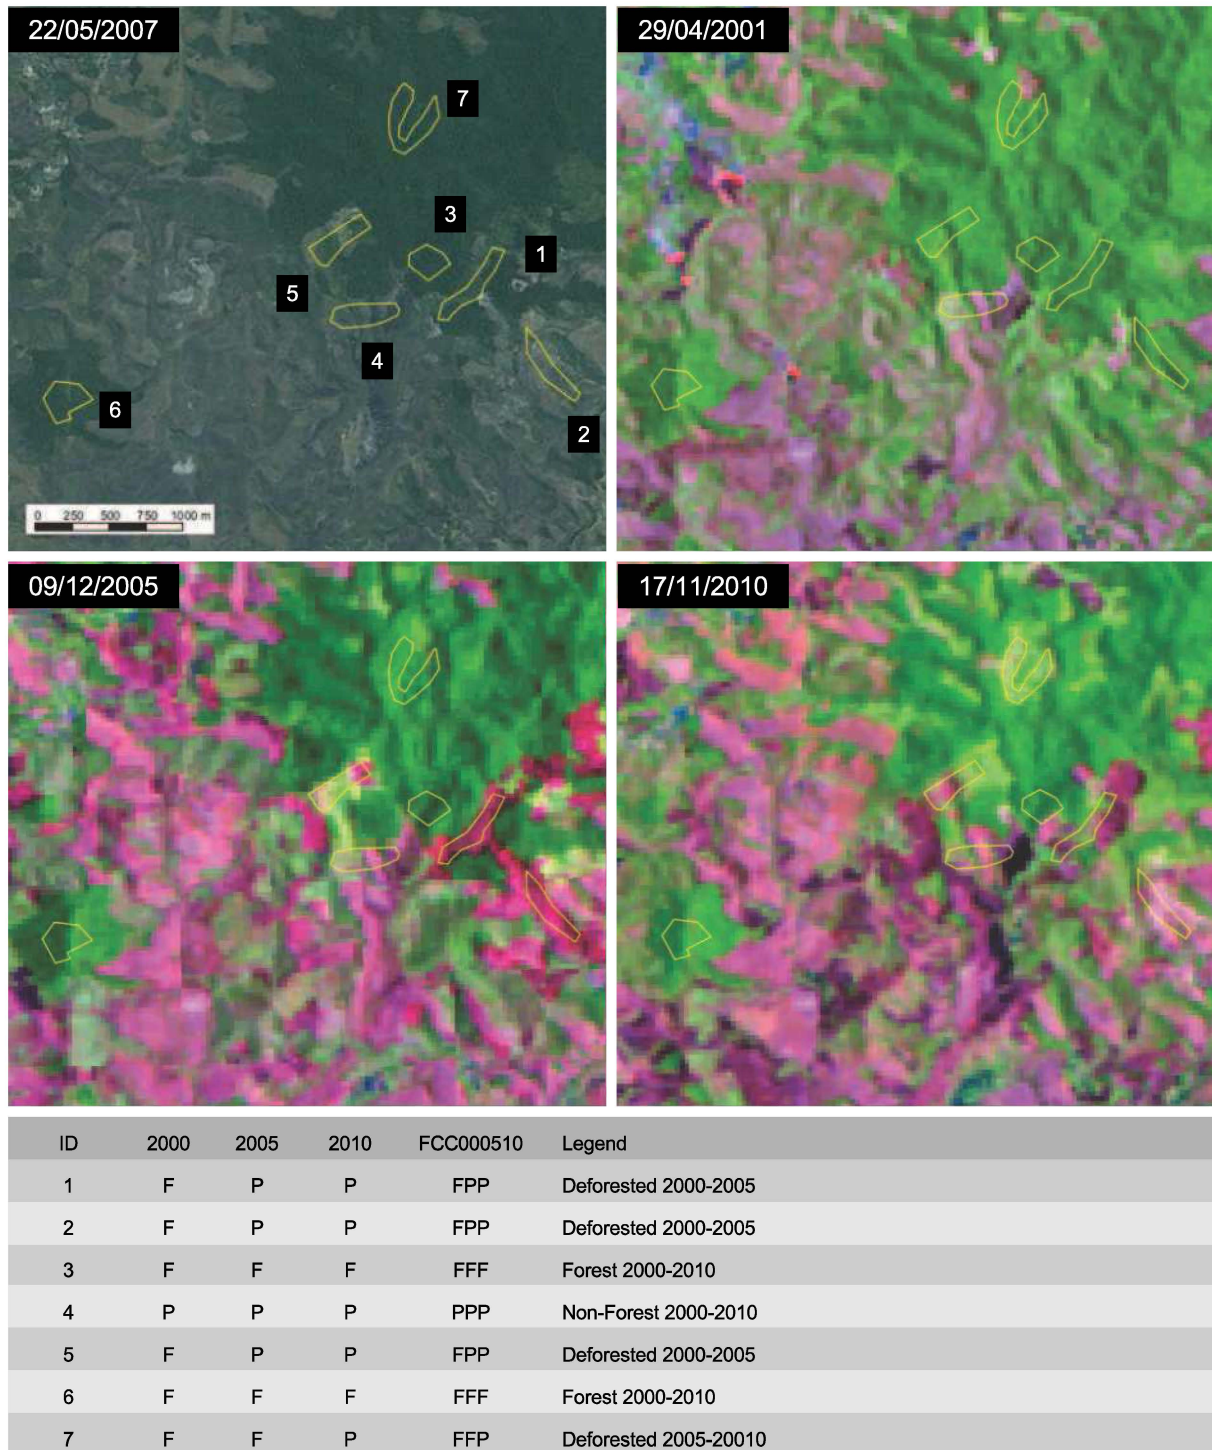


Figure 15 : Stable land cover and examples of visual interpretation of land cover change using QGIS, QuickBird/Google Earth images and Landsat images. From top left to bottom right: cluster of training plots overlaying QuickBird images from Google Earth (22/05/2007) and Landsat TM false colour composite RGB=4,5,1 acquired at dates 29/04/2001, 9/12/2005 and 17/11/2010. Individual observations for each date and final forest cover change class for the seven training plot are presented in the table of attributes below the images.

.2.4.3.2 Classification with Random Forests

Several authors have shown that land cover classifications with RF outperform classifications with other types of algorithms such as the classification by maximum likelihood and by support vector machines (Gislason et al., 2006, Schneider, 2012). RF is a decision tree algorithm considered to be an improved version of the Classification and Regression Tree (CART, Breiman et al., 1984). Basically, it randomly selects a sample of observations and a sample of variables many times (default value of 500) to produce a large number of small classification trees. These small trees are then aggregated and a majority vote rule is applied to determine the final category (Breiman, 2001). This algorithm can be considered as a black box, as no clear class statistical signature is computed. However it provides an internal classification accuracy measurement (out-of-the-bag error) and the relative importance of the variables, which provides valuable insight into the modelled complex relationship (see 3.3.3). We developed models which use the selected reflective bands (Landsat TM band 1, 4 and 5) and indexes (NDVI and NRI) for every date. These variables were selected for their well known land cover discriminating power and which, following some preliminary tests (not shown), led to no increase in accuracy when the remaining bands (2, 3 and 7) were added. Following recommendations from Rodriguez et al (2012), we used default parameters for the two main RF parameters (number of trees and the number of random split variables). We estimated classification accuracy using a confusion matrix obtained from a ad-hoc test procedure using 70% of the training plots as classification data and 30% of the training plots as test data. We optimized the training plot dataset until we reached maximum steady accuracy from this confusion matrix. This refinement task, also referred as internal validation (Fig. 2), was performed by adding new training plots to obviously misclassified locations or deleting some that may have been sources of confusion. This involved detailed analysis of the error matrix, training plot location, and map outputs at each classification run. Although all the categories were considered, we focused our attention on confusions related to land cover change categories. We finally used the entire training plot dataset to produce a FCC map of the whole study area.

.2.4.3.3 Sampling intensity and importance of variables

The classification described above required a high level of expertise (visual interpretation of images and interpretation of confusion matrices), which can be fastidious and time-consuming when large areas are involved. For that reason, we investigated which sampling intensity would be appropriate to achieve satisfactory classification and whether all the variables used were relevant in the modelling process. First, we tested a sampling intensity ranging from 30% to 90% of the entire training plot dataset. Two metrics, the out-the-bag error provided by the RF algorithm and overall accuracy were calculated using the remaining test plots not used to build the model. The out-of-the-bag error is an internal accuracy metrics calculated using

about one third of the input dataset not used for the construction of the trees, and is considered as an unbiased estimate of the error (Breiman, 2001). Second, we evaluated the importance of the variables used for the final classification model. Two measures exist in the RF algorithm to measure variable importance. We used only one, referred to as the mean decrease in accuracy. The latter applies variable permutation when constructing classification trees and measures the relative difference (decrease) in the out-of-the-bag error compared with a prior without-permutation test. A high decrease means the variable is important for the classification. Results are averaged on all trees and normalized on a 0-100 scale by the standard deviation of the differences.

2.4.4 Post processing

As previously mentioned in 3.3.1, clouds and shadows remained in the final output maps. The extent of clouds and shadows remaining in the raw classification output was less than 2.5% of the total study area for all sites except for the cloudy Comatsa site (14.1%). In order to produce a full coverage map and calculate accurate and conservative deforestation estimates, we used an auxiliary map showing the extent of forest in 2005 (MEFT, 2009). Cloud and shadow pixels in the final FCC map were then replaced by forest or non-forest pixel values from the 2005 map (figure 16). In addition, we applied a minimum mapping unit filtering process using an in-house Grass script that has two folds. First, deforestation patches with an area of less than 0.36 ha (2x2 pixels) were replaced by the majority class found in a 3x3 moving window. Second, a simple majority vote using the same 3x3 moving window was applied for other categories. The 0.36 ha threshold was chosen with respect to the geometric precision of the input datasets (around 1 pixel). This approach was considered highly conservative (no overestimation of deforestation) regarding deforestation intensity as no deforestation pixels were added and small patches were removed. In another study (Steininger et al., 2009), Landsat images with a resolution of 28.5 m allowed the production of a minimum mapping unit of 0.3 ha.




Figure 16 : Illustration of post-processing steps: 1) minimum mapping unit filtering of 0.36 ha using a 3x3 moving window that retains only 2x2 deforestation patches and applies a majority vote for other categories (first to second panel) and 2) cloud and shadow removal using the 2005 forest map (second to third panel). Green represents the extent of the forest, light yellow the non forest, orange deforestation in the 2000-2005 interval, and red deforestation in the 2005-2010 interval. White pixels represent clouds, and black pixels shadows.

2.4.5 Estimating deforestation rates

Deforestation rates can be expressed as the area deforested over a given period of time compared to the initial forest area (Puyravaud, 2003). Despite our objective of analyzing deforestation over a period spanning five years, selected suitable images oscillated around the pivot years 2000, 2005 and 2010 (table 1) resulting in variable time intervals between land-cover observations. Time intervals ranged from three years and five months to six years and three months, with one exception for the north-east site, which showed a time interval of 13 years for the first period and three years for the second. To account for these large time differences, we used a weighted mean to estimate the average time interval between land cover observations for each study area (Vieilledent et al., 2013). The weights corresponded to the area (in km²) of the scene with a given time interval. Following Puyravaud (2003), we used Eq. 1 to estimate the annual deforestation rate.

$$\theta = 1 - \left(1 - \frac{A_1 - A_2}{A_1} \right) \frac{1}{Y}$$

Eq.1

The annual deforestation rate θ was expressed as a function of A_1 and A_2 , the forest areas for the study areas at dates 1 and 2 and Y , the weighted average time interval. Y was expressed as

a function of the number N of the different time intervals t_n (with $n=1, \dots, N$) and the area of forest at date 1 with time-interval t_n (denoted s_n):

$$\text{Eq.2} \quad Y = (1/N) \sum_n t_n \left(s_n / \sum_n s_n \right)$$

2.4.6 Accuracy Assessment

Accuracy was assessed using a point sampling approach and following general guidelines, i.e. the use of a large sample and a low sample rate (Stehman, 2005; Duveiller et al 2008). In this study, we used a systematic stratified sampling design with two strata (figure 17). The first stratum was defined to assess the extent of land cover by creating a 2-km grid, each intersection of the grid being a sample location. The second stratum was designed to capture smaller pattern such as deforestation, and a hot spot analysis was thus performed to delineate such areas. We used the fire information resource management system (FIRMS, <http://firefly.geog.umd.edu/firms>) to set up a fire location database for the last decade. We intersected the point database with the 2-km grid and selected the tile with more than five fires and within a distance of less than 500 meters from the forest edge in 1990. The latter criterion was added in order to remove fire detection due to bushfire wherever possible. A 500-m grid was then created on these hot spot tiles, each intersection of the grid being a sample location. The two strata were merged and we finally obtained a total of 30 106 sampling points with 18 729 samples for stratum 1 (whole area) and 11 377 sample for stratum 2 (hot spots). At each point, the underlying pixel and its surroundings pixels (a total of 9 pixels) were visually interpreted by five photo interpreters who used the same protocol based on Qgis software. We particularly focused on the height of observation (scale) using zoom in and out functions to ensure the observation was made at pixel level. A majority vote rule was applied on the nine surrounding pixels to retain only one value for each point, thus corresponding to a sampling rate of 0.1% for the entire study area. Land cover and changes in land cover at the sampling points were classified by visual interpretation using the same method as that used for the FCC map, based on the same image mosaics. Accuracy was assessed using a confusion matrix that compared the visually interpreted sampling points and the FCC map, at the pixel level. We used the confusion matrix to estimate both the overall accuracy of the map and land category errors of commission and omission (Girard & Girard, 1999). In this study, we focused on category errors, which allowed us to derive the mean error of commission and omission for each category. This resulted in a first accuracy indicator referred to as per-pixel accuracy in this paper. We derived a second user-oriented indicator by calculating the relative difference in area derived from the point sampling approach and the FCC map. In the point sampling approach, areas were first derived using the formulas presented in Stach et al. (2009) and then using Eq.1 to calculate deforestation rates. Relative

differences in surface area were computed for the stable land cover categories and relative differences in the deforestation rate for the land cover change categories.

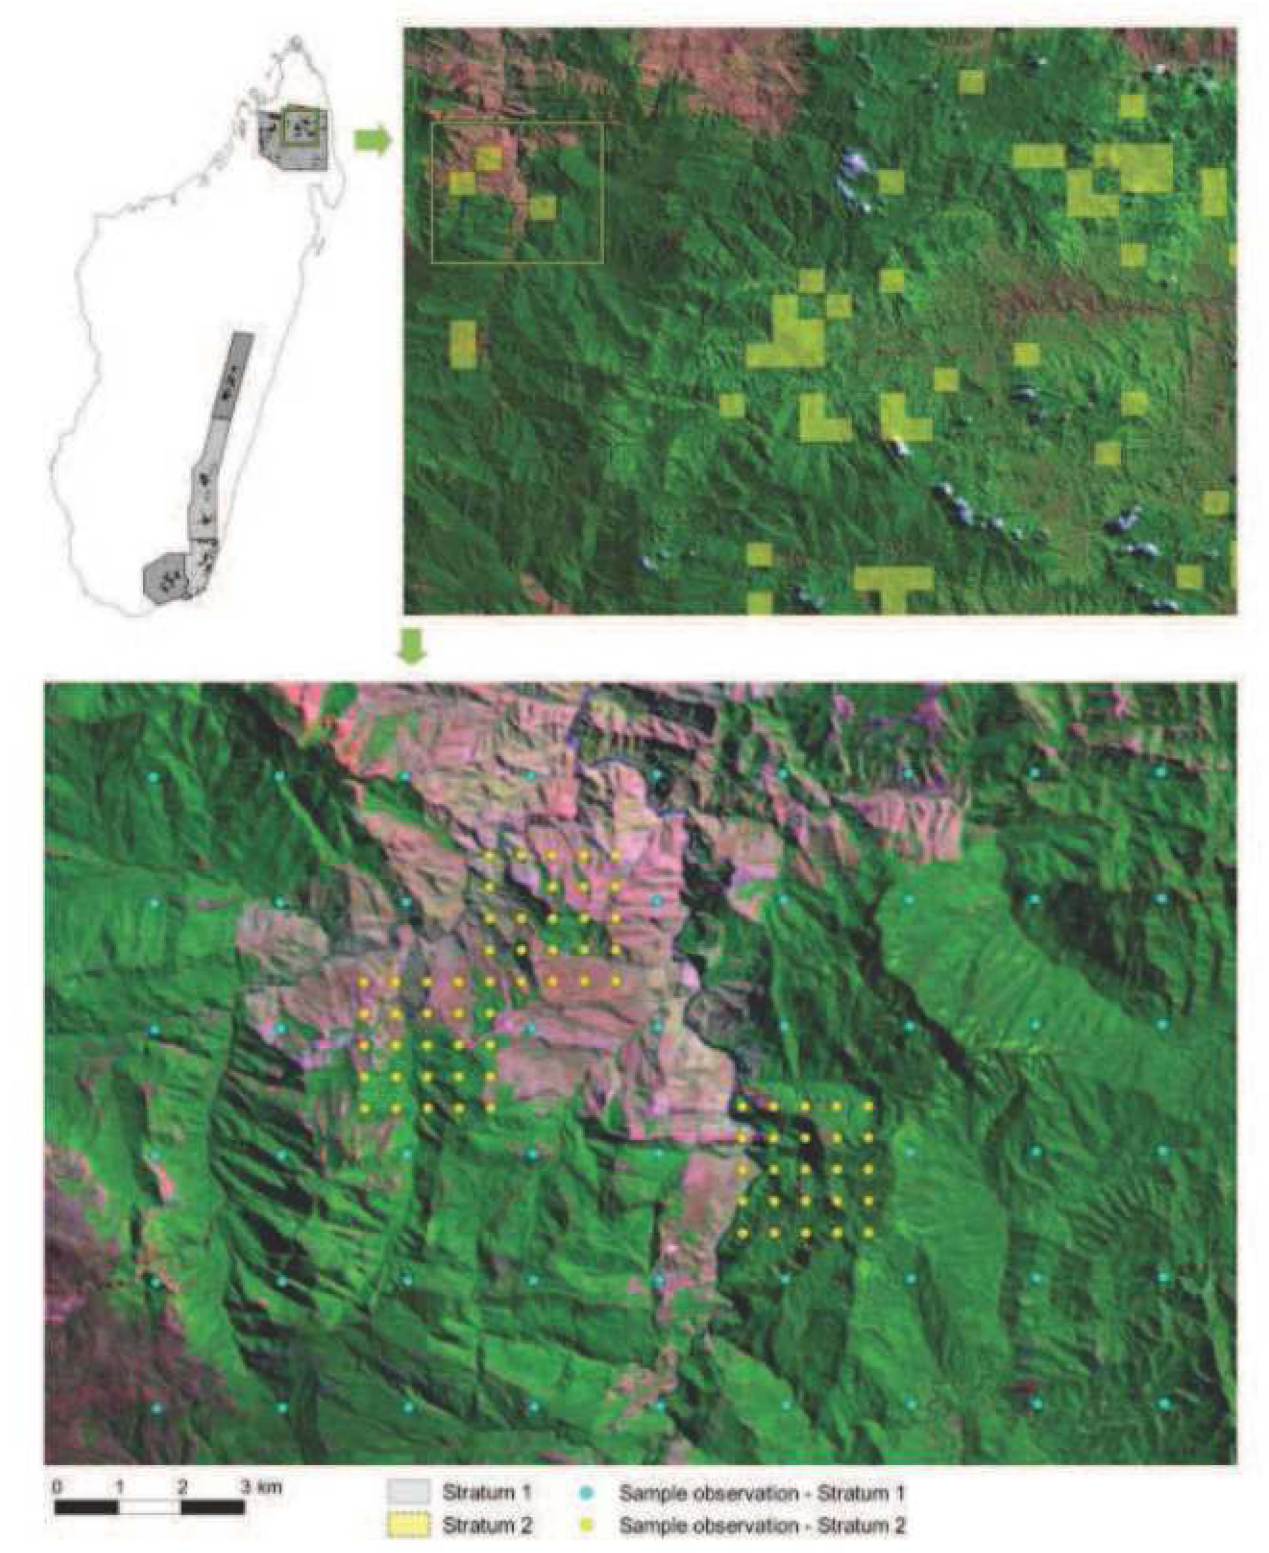


Figure 17 : *Illustration of the point sampling design with the two strata used for the assessment of accuracy. Stratum 1 corresponds to one sample every two kilometers over the entire study area (area in grey and blue dots) and stratum 2 corresponds to one sample every five hundred meters in previously located hot spot areas (area in yellow and yellow dots).*

2.4.7 Transparency and repeatability of the method

To achieve the maximum level of transparency and repeatability, efforts were made i) to minimize pre-processing steps, ii) to fully describe training plot polygons in a table of attributes, and iii) to use open source software (GRASS, QGis and R). These programs were used in a complementary fashion and, except for visual interpretation; all the steps were sequenced in a command line R-GRASS script available upon request from the authors.

2.5 RESULTS

2.5.1 Sampling intensity and importance of the variables

Our primary goal was to test the ability of the RF algorithm to map small forest cover change over large areas in two times periods. Several interesting conclusions can be drawn from the calibration step using RF. First the results of the sampling intensity test revealed substantially different patterns for the out-of-the-bag accuracy computed by the algorithm and overall accuracy computed from the test dataset (figure 18 f,g,h,i,j). The former showed a relatively homogeneous value of 0.95 with a maximum variation of 0.03 for the whole sampling intensity range, whereas the latter produced values ranging from 0.67 to 0.88. We further analysed the trend of overall accuracy with an increasing number of plots used in the calibration. There was a clear improvement in accuracy with an increase in sampling intensity despite the fact the trend was not linear. It should be noted that at this stage, only overall accuracy was observed from the point of view of the producer and class level results will be presented from the point of view of the user in section 4.2 below. These tests were carried out on the entire training plot dataset which was composed of 160 to 295 training plots per study area, 39-117 plots being interpreted as stable land cover and 22-51 plots as land cover change (figure 18 a,b,c,d,e). It should be noted that we observed only small patches of deforestation (figure 15), with a median size of 3.1 ha. Second, regarding the importance of the variables, results showed that certain Landsat bands played a more important role than others in the classification (Fig. 6 k,l,m,o,p). We noted the importance of band 5 and band 1 in every study area and particularly for the Comatsa, Fandriana and Mandrare watersheds. Surprisingly, the vegetation indexes (NDVI and NRI) did not have higher discriminative power than these two reflective bands. All the variables had more than 40% relative importance in each study area. Finally, five cloud-free maps of forest cover change (FCC) or gross deforestation over 7.7 million hectares were produced using Landsat images. Examples of the output maps are presented in figure 19

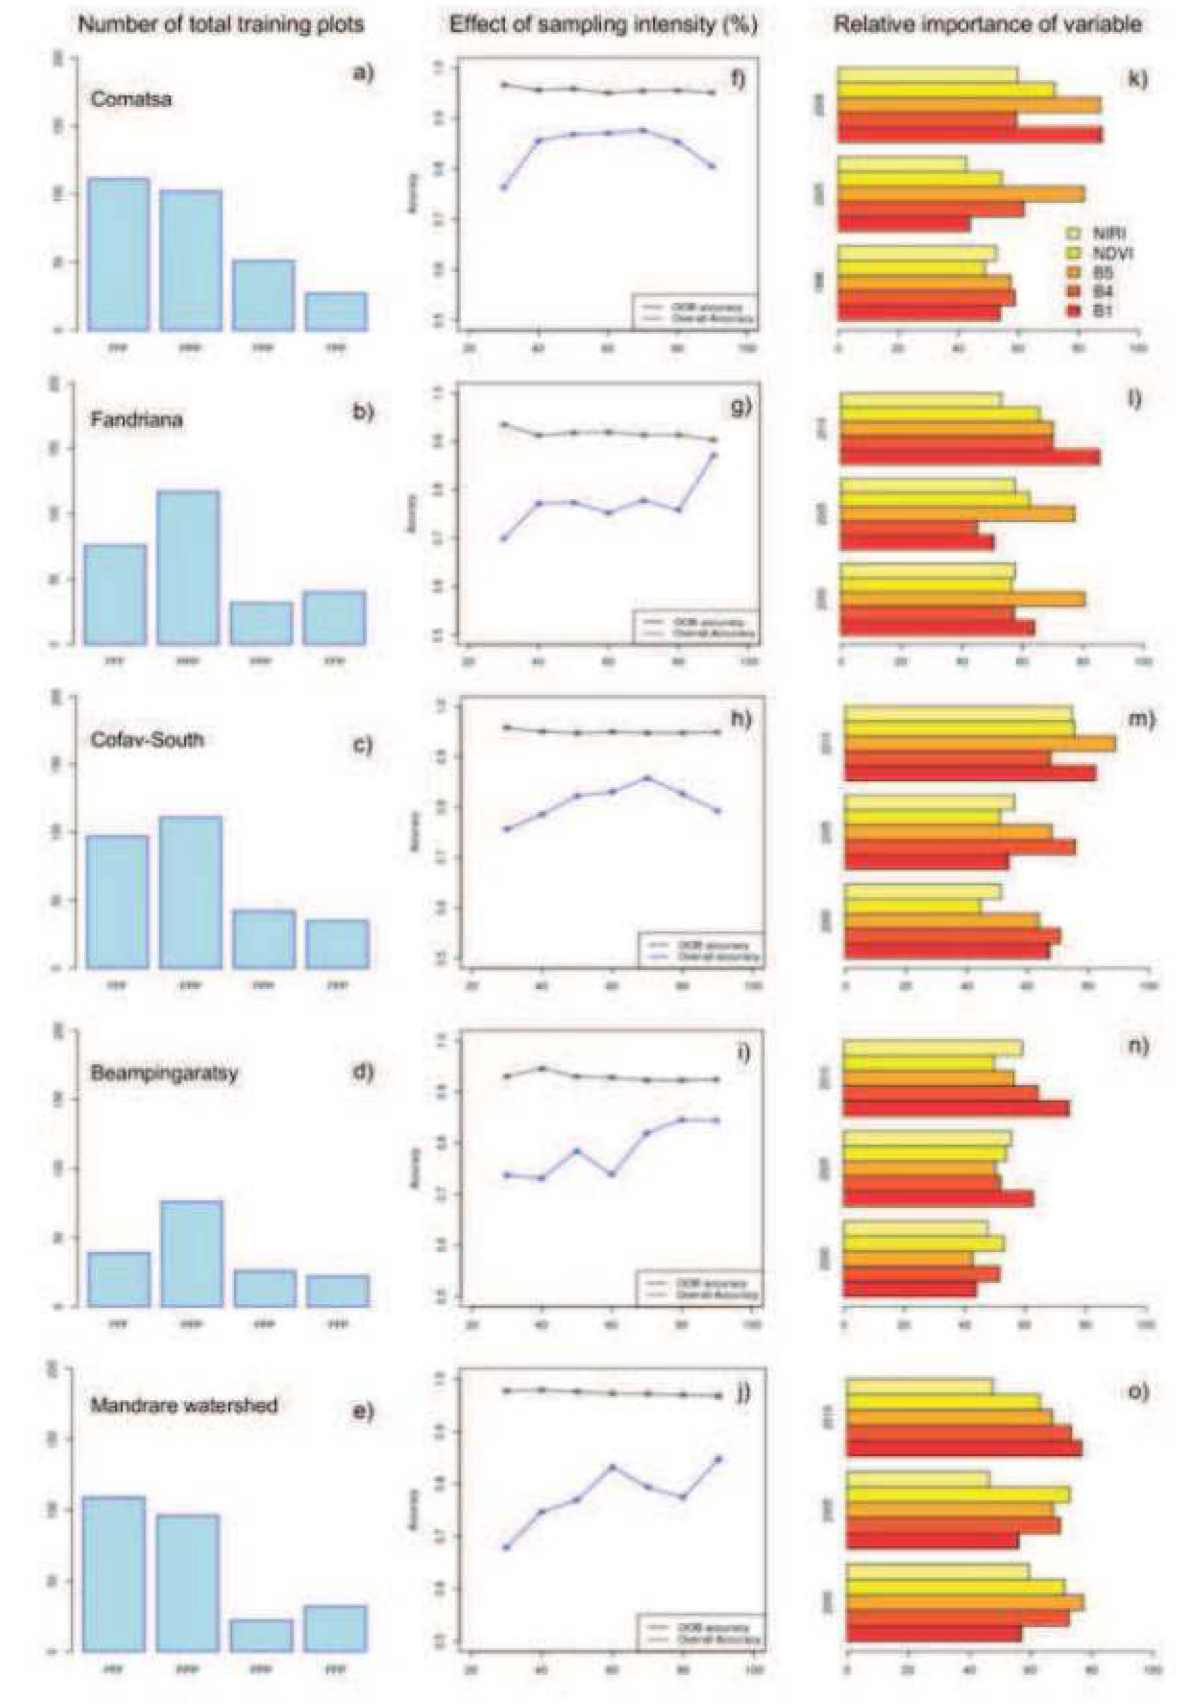


Figure 18 : Random forest calibration summary statistics. The first column corresponds to the number of overall training plots, the second column to the sampling intensity test and the third column to the relative importance of the variables.




Figure 19 : Satellite images and final map of forest cover change for the periods 2000-2005-2010. a) QuickBird/Google Earth acquired on March 17, 2011. b) Landsat false colour composite RGB=TM5-3-2 acquired on November 17, 2010. c) Forest Cover Change 2000-2010 map, green represents the extent of the forest, light yellow represents non-forest, orange represents deforestation between 2000 and 2005, and red represents deforestation between 2005 and 2010. The FCC map is available in kmz format in supplementary material.

2.5.2 Accuracy assessment

2.5.2.1 Per-pixel accuracy

Results of accuracy assessment at the pixel level are presented in the confusion matrix (tableau 4) and figure 20. Regarding the error matrix, although overall accuracy was satisfactory (83.3%) as was the accuracy of forest and crop land categories (from 81.5 to 90.3%), significantly lower values were obtained for deforestation classes. We recorded producer accuracies of 40.5 and 41.6% for the first and second deforestation periods respectively, and user accuracies of 57.2 and 64.3% for the same periods. Confusions were identified between forest and cropland categories but to a very limited extent between forest and deforestation classes. The matrix also highlighted cloud and shadow point observations (category 999 with 581 points) which can be considered as “uncategorised” since the interpretation of the three time series did not allow these points to be attributed to other land categories. By removing these points for testing purposes, we observed a limited increase (2% to 3%) in user accuracy in the forest (FFF) and deforestation in the second period (FFP) categories. Also, only a few points (n=62) were observed to be cropland or savannah (PPP) whereas they were mapped as rock or bare soil (OOO). In addition, the pattern of

deforestation on the FCC map can be considered conservative (i.e. deforestation is not overestimated) for two reasons. First, the number of deforestation observations was around 30% to 35% lower for the FCC map than the observations made at sampling points. Second, the errors of omission were significantly higher than the errors of commission, which suggests that deforestation was rarely predicted where forest or cropland was observed. We observed similar trends at each site with lower values for land cover change categories compared with steady land cover categories (figure 20, b).

.2.5.2.2 *Relative difference measurement*

Based on surface areas computed from both the FCC map and the point sampling method, we computed the relative difference on the surface area (Forest and cropland/Pasture) and the annual deforestation rate (deforestation period 1 and 2) (figure 20 c). We found very small average relative difference (2%) between the estimated surface area for Forest and crop & Pasture. All the study areas showed values below 10% except for the Mandrare deciduous dry forest, where a difference of 14.6% was recorded.

On the other hand, relative differences in annual deforestation rates varied (from 8.5 to 49.5%) depending on the study area and the study period. These relative differences combined multiple sources of errors in both datasets, including supervised classification errors on the FCC map and manual labelling of the land cover in the point sampling approach. However, combining all the study areas, we measured a satisfactorily limited difference between the two historical datasets, 14% for the first period and 21.1% for the second.

Tableau 4 :Error matrix at pixel level with the FCC map and the observed sample points

Category	Observation at sample points							P (%)	U (%)	P*(%)	U*(%)
FCC map	FFF	PPP	HHH	FFP,	FPP	999	Total				
FFF	9045	1113	3	338	321	279	11099	86.7	81,5	88.5	84.7
PPP	1189	14995	6	236	391	240	17057	90.3	87,9		
HHH	7	154	13	3	1	2	180	59.1	7.2		
FFP,	80	77		439	54	33	683	40.5	64.3	41.0	60.7
FPP	108	205		69	546	27	955	41.6	57.2		
OOO	1	62					63				
Total	10430	16606	22	1085	1313	581	30037				

Note: Overall accuracy = 83.3%; Kappa Index of Agreement = 0.70. Note 2: FCC: Forest Cover Change; FFF: Forest 2000-2010; FFP, Deforestation between 2005 and 2010, FPP:

Deforestation between 2000 and 2005; PPP: Savannah and cropland; HHH: Wetland; OOO: Other land, including Bare soil and rock; 999: Cloud or shadow; P, Producer accuracy; U, User accuracy; *: mean estimates of stable land cover and land cover change categories.

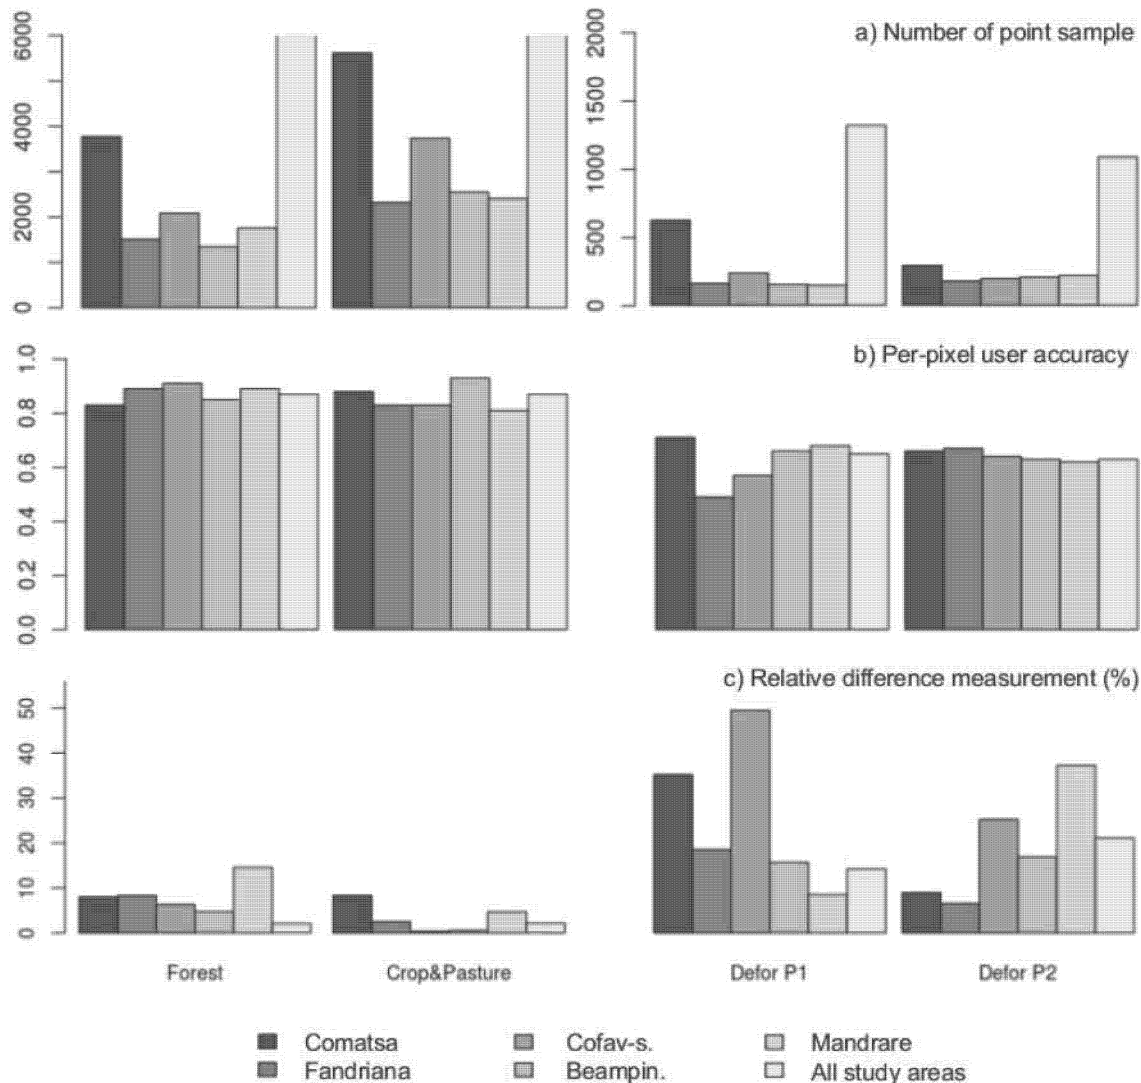


Figure 20 :Accuracy assessment. a) Number of samples observed in each category, b) per-pixel accuracy, and c) relative difference (area and deforestation rate) between point sampling and FCC approach. Defor P1: Deforestation in period 1 (2000-2005), Defor P2: Deforestation in period 2 (2005-2010).

2.5.3 Analyses of deforestation estimates and trends

The FCC maps were then used to derive forest area (tableau 5) and deforestation estimates (tableau 6) statistics for the study areas and the project sites. We measured a total forest cover of 2 407 thousand hectares (kha) in the whole study area and 528 kha in the project sites in 2010. This represents 25.5% and 5.6% of the national natural forest cover respectively (MEFT, 2009). According to the latest vegetation map (Moat and Smith, 2007), the present

study covers 43.3% of the humid forest and 20.6% of dry forest. We measured 174 725 ha of deforestation in the first period and 108 983 ha in the second period corresponding to a mean deforestation rate of 1.17%.yr-1 and 0.94%.yr-1 in the study areas. In the project sites, the figures were significantly lower, 0.64%.yr-1 and 0.55%.yr-1 (tableau 6). We also observed high variability of the annual deforestation rate depending on the study area. The lowest rates were observed in the tropical humid forest northern site (0.19%.yr-1) and in the dry spiny forest located in the southern part (0.28%.yr-1). The highest deforestation rate (2.48%.yr-1) was observed in the Fandriana site. We identified an overall slight decrease in the annual deforestation rate when the figures for the first period were compared with those for the second period. Only two study areas showed a significant change in the deforestation rate: a decrease in Cofav-south and an increase in Comatsa. Within the project sites, the changes were more marked: four out of five project sites underwent a significant change.

Tableau 5 :Forest surface in thousands of hectares for each study area and its related project site

Forest areas in 2010 (ha x 1000)	Type	Study area	Project site
Comatsa	humid	1 008	216
Fandriana	humid	275	24
Cofav-south	humid	489	113
Beampingaratsy	humid	263	54
Mandrare	spiny	372	122
All		2 407	528

Tableau 6 :Deforestation estimates for each study area and its related project site. * The period is approximate in this table. It is valid for all sites except Comatsa. For the exact date of the processed image, see table 1.

Gross deforestation	ha.y ⁻¹	%y ⁻¹		
Period*	2000-2005	2005-2010	2000-2005	2005-2010
Study areas				
Comatsa	8 365	8 859	0.77	0.86
Fandriana	8 255	6 875	2.50	2.33
Cofav-South	7 238	4 739	1.36	0.93
Beampingaratsy	2 890	2 800	1.01	1.03
Mandrare	1 791	1 873	0.46	0.50
All	28 540	25 145	1.17	0.94
Project sites				

Comatsa	687	402	0.31	0.19
Fandriana	721	656	2.48	2.53
Cofav-South	1 537	745	1.27	0.64
Beampingaratsy	336	508	0.59	0.92
Mandrare	350	545	0.28	0.44
All	3 630	2 856	0.64	0.55

2.6 DISCUSSION AND CONCLUSION

2.6.1 The accuracy of the method

Results concerning accuracy showed averaged user accuracy of 84.7% for stable land cover and 60.7% for land cover change at the pixel level. For the whole study area, we recorded relative differences between wall-to-wall and point sampling estimates of 2 % and 21.1 % for stable land cover and land cover change categories respectively . Concerning per-pixel measurement accuracy, we found that overall accuracy and stable land cover accuracy were consistent with that of other studies which used Landsat imagery to map deforestation at sub-national scale (Huang et al., 2009; Duveiller et al., 2008). These authors obtained accuracy measurement of 92% and 93% or higher on average. However, our land cover change accuracies were lower. Our values cannot be compared to other studies as change at pixel level is rarely validated because of the technical challenge of collecting an accurate reference dataset (Foody, 2010). We observed significant discrepancies between producer (41%) and user accuracy (60.7%). This suggests that the map we produced tends to omit deforestation rather than predicting deforestation beyond its true extent. Relative difference measurements showed a quite different pattern. Forest and non-forested areas measured on the FCC map and the point sampling were very similar. Land cover change categories also showed very good agreement on the measured annual deforestation rate. Overall, these results suggest that stable land cover and land cover change have significantly different accuracy magnitudes. In this respect, when developing a change detection analysis, special efforts should be made to record change class accuracy (Fuller et al., 2003). The stratified systematic sampling validation procedure presented in this study was particularly ambitious (more than 30 000 points observed), since we wanted to obtain independent and statistically valid estimates. Even with this intense visual-interpretation effort, we only obtained a few hundred points that fell within the deforestation categories. It should be noted that the visual-interpretation process is also highly prone to misclassification (interpreter subjectivity errors). Therefore, the validation process applied in this study and discussed above refers more to relative accuracy assessment or consistency assessment. To better account for subjectivity errors, a preliminary trial should be conducted consisting of repeated observation of a sample subset by

all the photo interpreters. Although simple, this technique is also criticable and time consuming since the sample subset has to be representative of all the observations.

2.6.2 Comparison with other annual deforestation rate estimates

This paper shows that for all study areas combined, the mean deforestation rate during the 2000-2005 period was 1.17%.yr-1 and 0.94%.yr-1 during the 2005-2010 period. We further investigated the results of this study by comparing them with previous estimates at national and sub-regional scale. Madagascar is recognized to be the country with the highest annual deforestation rate of hot spots, up to 4.7%.yr-1 according to Achard et al. (2002). Previous studies of deforestation in Madagascar included a four-date analysis, from 1950 to 2000 (Harper et al., 2005), and a three-date analysis, from 1900 to 2000 (MEFT, 2009), both at national scale, using also Landsat TM images. The latter recorded a decrease from 0.8% 1990-2000 to 0.53%.yr-1 for 2000-2005. MEFT (2009) was compared with the FCC map presented in this paper using the same study areas and for all the periods of time covered (tableau 6). We found limited agreement between the two FCC maps on the overlapping period (2000-2005). We identified four possible explanations for these marked difference. First, the date of the satellite images used in MEFT (2009) was not known exactly, and so a fixed time step of 5 years was used. From our experience, we are aware that the time interval is rarely exactly five years (tableau 3). This can lead to marked variations in annual deforestation rates (Puyravaud, 2003, Vieilledent et al., 2013). Second, in the map by MEFT (2009), there is still a remaining cloud and shadow class which may conceal large local forested/deforested areas. Third, the minimum mapping unit post-processing step may be responsible for a fair amount of difference. Indeed, the FCC map produced in our study used a 0.36 ha MMU whereas the MEFT (2009) FCC map used a 2 ha MMU, which may overlook many small shifting cultivation plots. Lower values in the first three study areas may be partly explained by this. Finally, the definition of forest was not exactly the same in the two studies, especially the definition of dry forest (2 m vs. 5 m minimum height). However, this may not be a real reason in tropical humid forest study areas because forest plots above the defined height are easily recognized. Moreover, the trend measured is highly informative due to the fact that an increase or decrease in the rate of deforestation that occurs several times in a five-year period is unlikely at sub-regional scale. In this respect, the FCC map produced in this study was considered coherent, as the maximum change recorded was a 30% decrease in the rate of deforestation between the two periods studied in this paper.

2.6.3 On the methodology

The method presented in this study was tested in one of the most difficult tropical regions for forest cover change monitoring since it covers a wide area with small deforestation plots

(slash and burn practices) on steep slopes with frequent to permanent cloud cover. The study produced two main results.

First, using stacked multi-date images is a powerful way of reducing classification errors, and enables better characterisation of small complex land cover change status. While it is clearly useful to perform a bi-temporal land cover change analysis to produce a transition matrix with no prior information, this method is limited when the change monitored is small compared to the image resolution. In this context, small geometric and thematic errors such as confusion between subtle land cover classes (e.g. two different forest strata, thicket/dry forest, regeneration/fallow, etc.) may greatly compromise true detection of change. As previously observed by Fuller et al (2003), classification errors may be of the same magnitude as the change itself or even greater. On the other hand, this study confirmed recent observations (Schneider, 2012) that multiplying image datasets acquired at different dates allows successful characterisation of land cover and land cover change by incorporating seasonal and vegetation dynamics even in complex and heterogeneous situations. The drawback of the method is that the change class needs to be identified prior to image processing. Consequently the approach developed in this study should be used with clear objectives and known change categories.

Second, with complex datasets and land cover, a machine learning algorithm should be used. Random Forest was found to significantly improve accuracy and the related visual output when a supplementary training plot was added. This study confirmed that RF (like any decision tree algorithm) requires additional high quality training plot data (Gislason et al., 2006). The availability of VHR images such as the QuickBird/Google Earth image partially fulfils this need for information without extensive field surveys. Refinement of the output was mainly based on the confusion matrix set using a test dataset. Unlike Rodriguez et al. (2012), who suggested using the out-of-the-bag estimator as an unbiased classification accuracy estimator, we found that this indicator was not appropriate for reliable assessment of overall accuracy. Furthermore, optimal sampling intensity was difficult to assess since, contrary to expectations, the trends of accuracy measurement with increasing sampling intensity did not show the same pattern depending on the study area. The reason may be the variability of the results, which, as shown by Schneider (2012) can be high, depending on the experimental design. In this study, the test set was sufficiently large to provide unbiased estimates but not to assess the variability of the error using k-fold cross validation for some categories. Therefore, further calibration tests using k-fold cross validation or repeated bootstrap samples as well as additional training samples would be required to draw valid conclusions on minimum sampling requirements.

Tableau 7 : *Comparison of annual deforestation rates for different periods.*

Study area	Period	MEFT <i>et al.</i> , 2009	FCC, present study
Comatsa	1990-2000	0.33	
	2000-2005	0.11	0.77
	2005-2010		0.86
Fandriana	1990-2000	1.57	
	2000-2005	1.45	2.50
	2005-2010		2.33
Cofav-s	1990-2000	1.21	
	2000-2005	0.19	1.36
	2005-2010		0.93
Beampingaratsy	1990-2000	0.88	
	2000-2005	1.76	1.01
	2005-2010		1.03
Mandare watershed	1990-2000	0.19	
	2000-2005	0.92	0.46
	2005-2010		0.50

2.6.4 On the forest monitoring perspectives

Madagascar is one of the tropical countries involved in the UNFCCC REDD+ mechanism, which requires setting up a national forest monitoring system that enables accurate and timely monitoring of deforestation, degradation and increase in carbon stocks. DeFries et al. (2007) drew up guidelines to fulfil the need for monitoring tropical deforestation and identified both the sampling strategy and exhaustive mapping (wall-to-wall) as an operational solution. Broich et al (2009) suggested considering the point sampling approach as a timely and cost effective component of a monitoring system. This paper shows that, contrary to general guidelines on GHG reporting techniques, which suggest using one or the other (GOFC-GOLD, 2010), the two methods are both essential and complementary.

On one hand, exhaustive mapping provides invaluable spatially explicit information which can be used not only for greenhouse gas monitoring but also for forest conservation planning (Harper et al., 2005) and spatial modelling of deforestation (Vieilledent et al., 2013). On the other hand, point sampling has several non-negligible advantages: i) it is less demanding technically, ii) it can address more subtle changes in land use (e.g. degradation, regeneration) and iii) it reduces systematic errors thanks to full visual inspection. The main drawback is the time required for the visual interpretation and for the training session on the image interpretation protocol. In our study, we reached 400-600 point observations per photo

interpreter per day, which is a large number of points but with a small sampling rate (see section 3.4). In this paper, we argue that both approaches should be implemented, point sampling being an integral part of the wall-to-wall work flow. To date, there are no widely accepted validation standards for studies of forest cover change, partly because retrieving a reference dataset is challenging (Foody, 2010). Even if the point sample includes errors, the analysis of consistency errors between the two datasets is repeatable, transparent and produces intelligible results (e.g. in this study, less than 10% errors for stable land cover categories, around 20% for land change cover categories), provided that a consistent sample design is used. More generally, if a point sample database on land cover status (current and past) is maintained, it could be used as an independent validation dataset.

In addition, this study focused on gross deforestation, which was previously identified as the main source of anthropogenic GHG emission in Madagascar (RPP, 2010). More subtle changes, such as regeneration or degradation, also take place in Madagascar and should be monitored as part of GHG reporting tasks but more importantly with respect to biodiversity and forest resources.

Although the Landsat resolution was acceptable for a five-year deforestation study, it did not allow visual discrimination between a regenerated forest and a fallow and between a degraded forest and an intact forest. Regarding clear cut of forest, in this study we measured a median plot size of 3,1 ha in a five year period, which roughly corresponds to a plot size 0.6 ha on a annual basis (~7 Landsat pixels). The detection of clearings may then be jeopardised if one wants to implement a forest monitoring system with measurements made at intervals of less than five years. These difficulties were summarized by DeFries (2007) “Smaller clearings [compared with clearing for settlement] and more heterogeneous landscapes require data with higher spatial resolution (5–15 m) and greater involvement of an interpreter for visual analysis and more complex computer algorithms that detect less pronounced differences in spectral reflectances”.

Therefore 10-m resolution images would greatly improve deforestation monitoring and would also enable detection of regeneration and degradation. Timely monitoring could be achieved in the future thanks to the recent activation of the SEAS-OI (Surveillance Environnemental Assistée par Satellite dans l’Océan Indien), a satellite image reception antenna based in Reunion island whose reception area covers the whole of Madagascar, and the ESA Sentinel-2 platform due to be launched in 2013. Based on open source software that is able to handle large datasets, this method will facilitate further implementation of accurate, cost-effective and reproducible forest monitoring systems.

2.7 Acknowledgment

We thank three anonymous reviewers for their helpful comments leading to major improvements in the manuscript. The authors would like also to thank the five photo interpreters, who carried out the visual interpretation for the accuracy assessment, and the WWF local coordinators for their useful feedback on the resulting maps. This study is part of the Holistic Conservation Programme for Forests (PHCF) in Madagascar. The PHCF is a REDD+ pilot-project funded by Air France and jointly implemented by WWF and GoodPlanet foundation.

3 Conclusion de l'étude

En conclusion, nous reprenons les trois problématiques qui ont été posées en introduction.

- **Quels sont les tendances récentes de la déforestation à Madagascar à l'échelle régionale ?**

Nous avons fourni à travers cette étude un nouvel éclairage sur les dynamiques de la déforestation, de 2000 à 2010. On constate tout d'abord des pressions très contrastées selon les régions d'études, de 0,4 à 2,3 %. an^{-1} . Les tendances également ne sont pas homogènes, sur les cinq zones d'études, deux montrent des tendances à la hausse, et trois à la baisse. A une échelle régionale, nous avons observé une légère diminution du taux de déforestation, passant de 1,17%. an^{-1} à 0,94%. an^{-1} . Cette étude ayant été réalisée en début de thèse, d'autres études ont été réalisées depuis cette première publication. Elles seront discutées dans la conclusion générale (chapitre 5).

- **Peut-on suivre la déforestation liée à la pratique de défriche brûlis, sur de petites parcelles, avec précision ?**

Les indicateurs globaux de qualité de la cartographie sont satisfaisants au regard des standards (83,3 % de précision globale). Ils sont aussi satisfaisants lorsque que l'on compare les différences entre les approches « wall-to-wall » et par échantillonnage, avec moins de 2% d'écart sur les classes forêt et savane. Cependant, nous avons également montré que les niveaux de précision des classes de changements (déforestation sur 2000-2005 et 2005-2010) étaient bien en dessous (60,8%) des classes forêts et savane (84,7%). Vu l'ampleur de la démarche de qualité, ces chiffres nous semblent réalistes. Le seuil minimum de cartographie utilisé (0,36ha, c.à.d. 2x2 pixel Landsat) nous semble adapté pour tenir compte de la précision géométrique des images. Cependant pour améliorer la détection des petites parcelles de défrichements sujettes à des régénérations rapides (en région humide) des données satellites avec des meilleures résolutions spatiales et temporelles seraient nécessaires comme par exemple les données SENTINEL-2 à 10 mètres de résolution disponible depuis novembre 2015.

- **Le cas échéant, quels sont les modalités pour un changement d'échelle, du régional au national ?**

La mise en place d'une chaîne de traitement sur logiciel libre et l'utilisation de données Landsat permet de passer facilement à une échelle nationale. La contrainte principale de cette méthodologie est la création d'une base de données de parcelles d'apprentissage et de validation de haute qualité. Cela demande de former des équipes d'expert photo-interpréteur. Cette étape garantit cependant la qualité des résultats et la bonne prise en compte des usages des terres présent dans le pays. Les autres contraintes techniques (ex. capacité de calcul, téléchargement d'images, etc.) sont à prendre en compte mais ne sont pas déterminantes.

4 References du chapitre 2

- Achard, F., Eva, H.D., Stibig, H-J, Mayaux, P., Gallego, J., Richards, T., & Malingreau, J-P. (2002). Determination of Deforestation rates of the World's humid tropical forests. *Science*, 297, 999-1002.
- Achard, F., Stibig H-J, Eva, H.D., Lindquist, E.J., Bouvet, A., Arino, O., & Mayaux, P. (2010). Estimating tropical deforestation from Earth observation data. *Carbon Management*, 1, 271-287.
- Aide, T.M., Clark, M.L., Grau, H.R, L-C, D., Levy, M.A., Redo, D., Bonill-Moheno, M., Riner, G., Andrade-Nunez, M.J., Muniz, M. 2012. Deforestation and Reforestation of Latin America and the Caribbean (2001-2010). *Biotropica*, doi. 10.1111/j.1744-7429.2012.00908.x
- Baccini, A. Goetz, S.J., Walker, S., Laporte, N.T., Sun, M., Sulla-Menashe, D., Hackler, J., Beck, P.S.A., Dubayah, R., Friedl, M.A., Samanta, S., & Houghton, R.A. (2012). Estimated carbon dioxide emissions from tropical deforestation improved by carbon density maps. *Nature Climate Change*, 2, 182-185.
- Bicheron P., Defourny P., Brockmann C., Schouten L., Vancutsem C., Huc M., Bontemps S., Leroy M., Achard F., Herold M., Ranera F. and Arino O., 2008. GlobCover 2005 – Products description and validation report, Version 2.1, 2008. Available on the ESA IONIA website (<http://ionia1.esrin.esa.int/>)
- Breiman, L., Friedman, J.H., Olshen, R.A., & Stone, C.J. (1984). Classification and Regression trees- Wadsworth & Brooks Wadsworth statistics probability series.
- Breiman, L., (2001). Random Forests. *Machine Learning*, 45, 5–32.
- Broich, M., Stehman, S.V., Hansen, M.C., Potapov, P., & Shimabukuro, Y.E. (2009). A comparison of sampling designs for estimating deforestation from Landsat imagery : A case study of the Brazilian Legal Amazon. *Remote Sensing of Environment*, 113, 2448-2454.
- Clark, M.L., Aide, T.M., Grau, H.R., Riner, G. 2010. A scalable approach to mapping annual land cover at 250 m using MODIS time series data: A case study in the Dry Chaco ecoregion of South America, *Remote Sensing of Environment*, 114, 2816–2832
- DeFries, R.S., Houghton, R.A., Hansen, M.C., Field, C.B., Skole, D., & Townshend, J. (2002). Carbon emissions from tropical deforestation and regrowth based on satellite observations for the 1980s and 1990s. *PNAS*, 99, 22, 14256-14261.

- DeFries, R., Achard, F., Brown, S., Herold, M., Murdiyarso, D., Schlamadinger, B., & de Souza Jr, C. (2007). Earth Observation for estimating greenhouse gas emissions from deforestation in developing countries. *Environmental Science & Policy*, 10, 385-394.
- Duveiller G. Defourny, P. Desclée, & B. Mayaux, P. (2008). Deforestation in Central Africa: Estimates at regional, national and landscape levels by advanced processing of systematically-distributed Landsat extracts. *Remote Sensing of Environment*, 112, 1969-1981.
- Freidl, M.A., McIver, D.K., Hodges, J.C.F, Zhang, X.Y., Muchoney, D., Strahler, A.H., Woodcock, C.E., Gopal, S., Scheinder, A., Cooper, A., Baccini, A., Gao, F., & Schaaf, C. (2002). Global land cover mapping from MODIS : algorithms and early results. *Remote Sensing of Environment*, 83, 287–302.
- Foody, G.M. (2010). Assessing the accuracy of land cover change with imperfect ground reference data. *Remote Sensing of Environment*, 114, 2271–2285.
- Fuller, R.M., Smith, G.M., & Devereux, B.J., (2003). The characterisation and measurement of land cover change through remote sensing: problems in operational applications? *International Journal of Applied Earth Observation and Geoinformation*, 4, 243-253.
- Gislason, P.O., Benediktsson, J.A., & Sveinsson, J.R. (2006). Random Forests for land cover classification. *Pattern Recognition Letters*, 27, 294-300.
- Girard M.C. & Girard C.M. (1999). *Traitement des données de télédétection*. Dunod Ed. Paris, 529p.
- Global Forest Resource Assessment, 2010. Main Report. Food and Agriculture Organization of the UN, Rome, Italy.
- GOFC-GOLD. (2010). A sourcebook of methods and procedures for monitoring and reporting anthropogenic greenhouse gas emissions and removals caused by deforestation, gains and losses of carbon stocks in forests remaining forests, and forestation, Report version COP16-1, GOFC-GOLD Project Office, Natural Resources Canada, Alberta, Canada, 210p.
- Goodman, S. M. & Benstead, J. P. (2005). Updated estimates of biotic diversity and endemism for Madagascar, *Oryx*, 39, 73-77.
- Grimm, R., Behrens, T., Märker, M., & Elsenbeer, H., (2008). Soil organic carbon concentrations and stocks on Barro Colorado Island – Digital soil mapping using Random Forests analysis. *Geoderma*, 146, 102-113.

- Gutman, G., Byrnes, R., Covington, M.S., Justice, C., Franks, S., & Headley, R. (2005). Towards Monitoring Land-Cover and Land-Use Changes at at Global Scale: The Global Land Use Survey. *Photogrammetric Engineering and Remote Sensing*, 64, 6-10.
- Ham, J., Chen, Y., Crawford, M.M., & Gosh, J. (2005). Investigation of the random forest framework for classification of hyperspectral data. *IEEE Trans. Geosci. Remote Sens.* 43, 492–501.
- Hansen, M.C., & Loveland, T.R. (2012). A review of large area monitoring of land cover change using Landsat data, *Remote Sensing of Environment*, doi:10.1016/j.rse.2011.08.024
- Hansen MC, Stehman SV, Potapov PV., Lovelan T.R., Townshend, JRG., DeFries, R.S., Pittman, K.W., Arunarwati, B., Stolle, F., Steininger, M.K., Carroll, M., & DiMiceli, C. (2008). Humid tropical forest clearing from 2000 to 2005 quantified by using multitemporal and multiresolution remotely sensed data. *Proc. Natl Acad. Sci. USA*, 105, 27, 9439–9444.
- Harper, G., Steininger M.K., Tucker, C.J., Juhn, D., & Hawkins, F. (2007). Fifty years of deforestation and forest fragmentation in Madagascar. *Environmental Conservation*, 34, 1-9.
- Harris, N.L., Brown, S., Stephen C. Hagen S.C., Saatchi S.S., ,Silvia Petrova S., Salas, W., Hansen, M.C., Potapov, P.V., & Lotsch, A. (2012). Baseline Map of Carbon Emissions from Deforestation in Tropical Regions. *Science*, 336, 22, 1573-1575.
- Huang, C., Kim, S., Song, K., Townshend, JRG., Davis, P., Alstatt, A., Rodas, O., Yanosky, A., Clay, R., Tucker, C.J., Musinsky, J. 2009. Assessment of Paraguay's forest cover change using Landsat observations. *Global and Planetary Change*, 67, 1-12.
- IPCC. (2006). IPCC guidelines for national greenhouse gas inventories, IGES, Japan, www.ipcc-nggip.iges.or.jp/public/2006gl/index.html.
- Lawrence, R., L., Bunn, A., Powell, S., & Zambon, M. (2004). Classification of remotely sensed imagery using stochastic gradient boosting as a refinement of classification tree analysis. *Remote Sensing and Environment*, 90, 3, 15, 331-336.
- Mayaux, P., Bartholomé, B., Fritz, S., Belward, A. 2004. A new land-cover map of Africa for the year 2000. *Journal of Biogeography*, 31, 861–877

- Mayaux, P., Gond, V., Bartholomé, E. 2000. A near real-time forest cover map of Madagascar derived from SPOT VEGETATION data. *International Journal of Remote Sensing*, 21, 16:3139-3144.
- MEFT, Ministry of the Environment, Forest and Tourism of Madagascar. (2009). Evolution de la couverture de forêts naturelles à Madagascar, 1990-2000-2005. Antananarivo, Madagascar, 132p.
- Moat, J., & Smith P. 2007. Madagascar vegetation atlas. Royal Botanic Gardens, Kew. UK
- Olander, L. P.; Gibbs, H. K.; Steininger, M.; Swenson, J. J. & Murray, B. C. (2008). Reference scenarios for deforestation and forest degradation in support of REDD: a review of data and methods *Environmental Research Letters*, 3, 025011
- Pelletier, J. Ramankutty, N., & Potvin, C. (2011). Diagnosing the uncertainty and detectability of emission reductions for REDD+ under current capabilities: an example for Panama. *Environ. Res. Lett.*, 6, 1-12.
- Pennec, A., Gond, V., & Sabatier, D. (2011). Tropical forest phenology in French Guiana from MODIS time series. *Remote Sensing Letter*, 2, 4, 337-345.
- Potapov, P.V., Turubanova, S.A., Hansen, M.C., Adusei, B., Broich, M., Alstatt, A., Mane, L., & Justice, C. (2012). Quantifying forest cover loss in Democratic Republic of the Congo, 2000–2010, with Landsat ETM+ data. *Remote Sensing and Environnement*, 122, 106-116.
- Puyravaud, J-P, 2003. Standardising the calculation of the annual rate of deforestation. *Forest Ecology and Management*, 177, 593-596.
- Rasi R., Bodart C., Stibig H.-J., Eva H., Beuchle R., Achard F., Carboni S., Simonetti D. 2011. An automated approach for segmenting and classifying a large sample of multi-date Landsat imagery for pan-tropical forest monitoring. *Remote Sensing of Environment*, 115, 12, 3659-3669
- Rasi R., Beuchle, R., Bodart, C., Vollmar, M., Seliger, R., Achard, F. 2012. Automatic Updating of an Object-Based Tropical Forest Cover Classification and Change Assessment. *IEEE Journal of Selected Topics in Applied Earth Observations Remote Sensing*, p. 1-8, ISSN 1939-1404, doi: 10.1109/JSTARS.2012.2217733
- Rodriguez-Galiano, V.F., Ghimire, B., Rogan, J., Chica-Oimo, M., & Rigol-Sanchez, J.P. (2012). An assessment of the effectiveness of a random forest classifier for land-

- cover classification. *ISPRS Journal of Photogrammetry and Remote Sensing*, 67, 93–104.
- RPP, Redd Readiness Preparatory Proposal. 2010. Plan de préparation à la REDD (R-PP). Antananarivo, Madagascar, 107p.
- Schneider, A. 2012. Monitoring land cover change in urban and peri-urban areas using dense time stacks of Landsat data and data mining approach. *Remote Sensing of Environment*, 124, 689-704.
- Song, C., Woodcock, C. E., Seto, K. C., Pax-Lenney, M., & Macomber, S. A. 2001. Classification and change detection using Landsat TM data: When and how to correct atmospheric effects? *Remote Sensing of Environment*, 75, 230–244.
- Stach N, Salvado A, Petit M., Faure, J.F, Durieux, L., Corbane, C., Jourbert, P., Lasselin, D., & Deshayes, M. (2009). Land use monitoring by remote sensing in tropical forest areas in support of the Kyoto Protocol: the case of French Guiana. *Int. J. Remote Sens.* 30, 19, 5133–5149.
- Steininger MK, & Godoy F, Harper G. (2009). Effects of systematic sampling on satellite estimates of deforestation rates. *Environ. Res. Lett.* 4, 034015.
- Stehman, S.V. (2009). Sampling designs for accuracy assessment of land cover. *International Journal of Remote Sensing*, 30, 20, 5243-5272.
- Stehman SV. (2005). Comparing estimators of gross change derived from complete coverage mapping versus statistical sampling of remotely sensed data. *Remote Sens. Environ.* 96, 466–474.
- Tucker, C.J., Grant, D.M., & Dykstra, J.D. (2004). NASA's Global Orthorectified Landsat Data Set. *Photogramm. Eng. Remote Sens.*, 70, 313–322.
- Vieilledent G., Grinand C. and Vaudry R. 2013. Forecasting deforestation and carbon emissions in tropical developing countries facing demographic expansion: a case study in Madagascar. *Ecology and Evolution*. Article first published online: 3 MAY 2013. [doi: <http://dx.doi.org/10.1002/ece3.550>]

Chapitre 3 – Estimation des stocks de carbone dans le sol

1	CONTEXTE DE L'ÉTUDE	84
1.1	CHALLENGES.....	84
1.2	INNOVATIONS	85
1.3	PROBLÉMATIQUES SCIENTIFIQUES	85
2	ESTIMATING TEMPORAL CHANGES IN SOIL CARBON STOCKS AT ECOREGIONAL SCALE IN MADAGASCAR USING REMOTE-SENSING	86
2.1	RÉSUMÉ	87
2.2	ABSTRACT	88
2.3	INTRODUCTION	89
2.4	MATERIAL AND METHODS	92
2.4.1	<i>Study Area.....</i>	<i>92</i>
2.4.2	<i>Field data collection and soil analysis</i>	<i>93</i>
2.4.3	<i>Factors used in the SOC extrapolation model</i>	<i>95</i>
2.4.4	<i>Spatial prediction over the study area</i>	<i>98</i>
2.4.5	<i>Prediction of SOC stocks in 1991</i>	<i>98</i>
2.4.6	<i>Detection of changes in soil carbon stocks</i>	<i>99</i>
2.5	RESULTS	99
2.5.1	<i>SOC stock plot dataset</i>	<i>99</i>
2.5.2	<i>Model accuracy assessment</i>	<i>100</i>
2.5.3	<i>Importance of soil carbon controlling factors</i>	<i>100</i>
2.5.4	<i>Spatio-temporal estimates of SOC stocks</i>	<i>102</i>
2.5.5	<i>Detecting changes in SOC stocks at regional scale</i>	<i>103</i>
2.5.6	<i>Changes in SOC stocks in deforested areas.....</i>	<i>106</i>
2.6	DISCUSSION	108
2.6.1	<i>How the SOC stocks distributed and what are the underlying drivers?</i>	<i>108</i>
2.6.2	<i>Can significant changes in SOC stocks be detected using satellite images?</i>	<i>109</i>
2.6.3	<i>How are the estimated changes in SOC stocks linked to land cover and changes in land cover?</i>	<i>110</i>
2.7	CONCLUSIONS.....	112
2.8	ACKNOWLEDGEMENTS	112
3	CONCLUSION DE L'ÉTUDE	113
4	REFERENCES DU CHAPITRE 3	115

« Soil organic carbon is a major indicator of land health and many ecosystem services (erosion control, water retention, climate change regulation), yet we do not know how to detect these change at management scale (landscape, region) »

(Smith, 2012)

“We know more about soils of Mars than about soils of Africa”

(Sanchez, 2009)

1 Contexte de l'étude

1.1 Challenges

Dans l'étude précédente nous avons pu actualiser la carte de la déforestation jusqu'en 2010, en s'attachant à caractériser les parcelles de défrichement avec précision. Notre objectif ici est de quantifier l'impact de ce défrichement sur les services écosystémiques rendus par le sol. On s'intéresse ici à l'indicateur carbone organique du sol (COS). Le COS est couramment utilisé comme substitut (« proxy ») de ces services, à savoir, l'atténuation du changement climatique, la production primaire, le contrôle de l'érosion et la rétention d'eau. Plusieurs challenges ont été identifiés. Premièrement, malgré son importance au niveau global (changement climatique) ou local (production primaire), on connaît peu les dynamiques du COS : elles dépendent des modes d'usages des terres et des conditions pédo-climatiques. C'est particulièrement vrai pour les pays en voie de développement qui n'ont généralement pas de dispositif expérimental de longue durée ni de système de suivi de la qualité des sols. C'est le cas de Madagascar, qui ne compte que quelques études locales sur des essais agronomiques de changement de pratiques agricoles au niveau de petites parcelles expérimentales. Les études existantes sont donc largement sous-représentatives des paysages tropicaux (Powers et al, 2011) et il y a un besoin urgent de développer des méthodologies qui puissent être appliquées à des échelles fines (plantation, paysage, projet) (Smith et al, 2012). Deuxièmement, la direction et magnitude des changements de stocks ne sont pas toujours en accord avec ce qu'on explique habituellement (ex. diminution du stock de carbone après déforestation à cause de l'érosion hydrique). Les changements de stocks de carbone après conversion d'une forêt en champ de culture peuvent aller de – 80% à +58% en une vingtaine d'années (Don et al, 2011) ! Cela souligne la complexité du fonctionnement du sol, des nombreuses interactions entre les éléments constituant le sol et leur spécificité en fonction des conditions locales (micro-climat, micro-topographie, itinéraire technique). Enfin, les nouvelles méthodologies de cartographie numérique des sols, utilisant de plus en plus des informations satellitaires, ont montré leur capacités à prédire les stocks de carbone à différentes échelles et notamment des résolutions fines de un à plusieurs dizaine de mètres (e.g. Vagen et Winowiecki, 2013). Elles n'ont pour l'instant pas encore été testées avec des données temporelles. En d'autres termes, il semble aujourd'hui possible d'exploiter le potentiel des archives satellites et acquisitions actuelles pour le suivi des variations de stockage du carbone dans le sol.

1.2 Innovations

Dans cette étude nous proposons plusieurs innovations :

- Quantification des stocks de carbone sur deux couches de sol (30 cm et 1 m) en s'appuyant sur des modèles de calibration spectroscopique pour le dosage du carbone organique et modèles verticaux de distribution des propriétés des sols ;
- Utilisation des données satellites et autres données environnementales haute résolution pour la cartographie des stocks de l'échelle du paysage à l'échelle de la région. La résolution de travail correspond à la résolution la plus fine des données utilisées, c'est à dire 30 mètres (images Landsat) ;
- Exploration du potentiel des données de radiométrie gamma (K, U, Th) pour expliquer la distribution du carbone organique du sol ;
- Évaluation des déterminants du stockage du carbone pour deux profondeurs de sol : sur 30 cm et 1 m de profondeur. Le modèle de distribution spatiale utilisé ici est l'algorithme Random Forest qui est de plus en plus utilisé pour la cartographie des sols ;
- Utilisation de données satellites en archive pour la prédiction des changements de stocks de carbone dans le sol sur une période de 20 ans (1991 à 2011). On utilise une approche simple par substitution des variables dynamiques représentant les propriétés des sols et de la végétation (données de réflectance du visible au moyen-infra rouge) ;
- Évaluation de l'effet de la déforestation sur le stock de carbone par croisement de la carte de déforestation présentée précédemment (chapitre 2) avec la carte de changement de stock de carbone produite.

1.3 Problématiques scientifiques

À travers cette étude, on cherche à répondre à ces trois questions :

- Quel est la distribution des stocks de carbone du sol et ses déterminants dans la zone sud est de Madagascar ?
- Peut-on détecter des changements significatifs de stocks de carbone de sol avec des images satellites ?
- Le cas échéant, quelle est la direction et la magnitude de ces variations pour des parcelles de forêt naturelle ayant été converties en champ de culture ?

2 Estimating temporal changes in soil carbon stocks at ecoregional scale in Madagascar using remote-sensing

Published in International Journal of Applied

Earth Observation and Geoinformation

C. Grinand^{1,2}, G. Le Maire³, G. Vieilledent⁴, H. Razakamanarivo⁵, T. Razafimbelo⁵, M. Bernoux¹

¹ IRD, UMR-Eco&Sols, 2 *Place Viala* - 34060 Montpellier cedex 2 - France.

² Etc Terra, 127 rue d'Avron, Paris - France.

³ CIRAD, UMR-Eco&Sols, 2 *Place Viala* - 34060 Montpellier cedex 2 - France.

⁴ CIRAD, UR 105 Biens et Services des Ecosystèmes Forestiers, TA C-105/D, Campus International de Baillarguet, F-34398 Montpellier Cedex 5 France

⁵ Laboratoire des Radio-Isotopes, Route d'Andraisoro, 101 Antananarivo, Madagascar

* Contact author: c.grinand@etcterra.org

2.1 Résumé

Le carbone organique des sols (COS) joue un rôle important dans la régulation du climat, notamment à travers les émissions de CO₂ liées aux changements d'usages des terres, comme la déforestation. Dans la plupart des pays, et notamment ceux en voie de développement, les données quantitatives de ces émissions manquent. Cette étude a pour objectif d'évaluer empiriquement les changements de stock de COS entre 1991 et 2011 à l'échelle des paysages, sans connaissance a priori, et en utilisant des données environnementales facilement accessibles. La zone d'étude est localisée dans la région sud-est de Madagascar, région aux taux élevés de déforestation et caractérisée par des climats humides et secs. Nous avons estimé les stocks de COS à partir de 95 placettes de 0,1 ha – pour différents modes d'usage des terres : forêt naturelle, champ de culture, jachère et prairie – et réparties sur une zone de référence de 40 000 ha. Nous avons utilisé l'algorithme Random Forest pour identifier les facteurs expliquant la distribution du COS. Nous avons ensuite prédit les stocks sur 30 cm et 1 m de profondeur sur une zone plus étendue de 400 000 ha. En changeant les facteurs représentant les conditions pédologiques et de végétation dérivés des images satellites, nous avons produit des cartes de stock de COS pour 2011 et 1991. Ces estimations et leurs incertitudes ont ensuite été combinées dans une étape de post-traitement afin de cartographier les variations de stocks significatifs. Les résultats de changement de stock ont enfin été croisés avec une carte de déforestation. Les résultats montrent que les variables géologiques, les précipitations et les températures sont des déterminants prépondérants de la distribution du carbone du sol. Les résultats confirment un rapide changement de stock les 5 à 10 années après déforestation, avec une perte moyenne de 10,7% et 5,2% pour les couches de 30 et 100 cm de sol respectivement sous climat humide. Aucun changement significatif n'a été observé pour la région sèche. Cette étude fournit des éléments importants pour la définition des niveaux d'émissions de GES à l'échelle du pays et contribue à une meilleure intégration de la ressource sol dans les politiques de gestion des terres.

Mots clefs:

Carbon organique du sol

Détection des changements

Cartographie

Télédétection

Déforestation

2.2 Abstract

Soil organic carbon (SOC) plays an important role in climate change regulation notably through release of CO₂ following land use change such a deforestation, but data on stock change levels are lacking. This study aims to empirically assess SOC stocks change between 1991 and 2011 at the landscape scale using easy-to-access spatially-explicit environmental factors. The study area was located in southeast Madagascar, in a region that exhibits very high rate of deforestation and which is characterized by both humid and dry climates. We estimated SOC stock on 0.1 ha plots for 95 different locations in a 43,000 ha reference area covering both dry and humid conditions and representing different land cover including natural forest, cropland, pasture and fallows. We used the Random Forest algorithm to find out the environmental factors explaining the spatial distribution of SOC. We then predicted SOC stocks for two soil layers at 30 cm and 100 cm over a wider area of 395,000 ha. By changing the soil and vegetation indices derived from remote sensing images we were able to produce SOC maps for 1991 and 2011. Those estimates and their related uncertainties were combined in a post-processing step to map estimates of significant SOC variations and we finally compared the SOC change map with published deforestation maps. Results show that the geologic variables, precipitation, temperature, and soil-vegetation status were strong predictors of SOC distribution at regional scale. We estimated an average net loss of 10.7% and 5.2% for the 30 cm and the 100 cm layers respectively for deforested areas in the humid area. Our results also suggest that these losses occur within the first five years following deforestation. No significant variations were observed for the dry region. This study provides new solutions and knowledge for a better integration of soil threats and opportunities in land management policies.

2.3 Introduction

Soils provide a wide range of ecosystem services including food production, water and climate change regulation but are under pressure from the increasing demands of a growing population (Milne et al, 2014). It is now widely recognized that soil organic carbon (SOC) is critical to most of these services. Restoring, increasing and protecting SOC is therefore a global priority and is covered by the United Nations Conventions on Climate Change, Desertification and Biodiversity (Cowie et al, 2011). Despite global awareness of climate change and emerging incentives such as reduction of deforestation and forest degradation (REDD+), little is known about soil dynamics associated to changes in land cover and land use. This is especially the case in developing countries that have not set up long term experiments for monitoring soil properties, even though such regions are liable to suffer from major land degradation as a result of deforestation and desertification. Guidelines drawn up by the international scientific community (IPCC, 2006) do not provide any practical means for assessing the complexity and diversity of soil functioning in areas where no inventory has been produced and which do not have any monitoring network (Smith et al, 2012). Practical limitations include the cost of taking soil inventories and the inability to determine the spatio-temporal changes in soil resulting from changes in land use and land management. Spatio-temporal methods using remote sensing technologies provide a means of measuring, monitoring and verifying SOC stocks (Post et al, 2001, Croft et al, 2012, Smith et al, 2012, Minasny et al, 2013).

Given the large amount of carbon stored in the soil worldwide (the top 100 cm soil layer holds 2.5 times more carbon than is found in the Earth's atmosphere, Lal, 2008), a small change in this stock will have a considerable impact on the carbon cycle, by significantly increasing or decreasing the carbon concentration in the atmosphere. The direction and magnitude of changes in SOC stocks are therefore of key importance for climate change policies. The literature generally agrees that conversion from forest to cropland is responsible for the greatest part of greenhouse gas emissions from changes in SOC stocks. There are two main factors: the reduction of input (forest litter vs crop residues) and increase in mineralization of organic matter due to tillage. However, the reduction in SOC stocks given in meta-analysis studies ranges from 42% (Guo and Gifford, 2002), 25% (Don et al, 2011), 15.4% (Powers et al, 2011) to 8.5% (Fujisaki et al, 2015) for forest converted into shifting cultivation or permanent cropland over one or two decades. On the other hand, fallow and pasture tend to increase the SOC stocks with respect to the original forest, by 8% (Guo and Gifford, 2002), 6.8% (Fujisaki et al, 2015), 10% (Powers et al, 2011). It may also lead to a decrease in stocks of up to 12%, as reported in Don et al (2011). The increase in stocks is explained by changes in root systems that tend to release carbon into the soil and the permanent input from grass or regenerating plant litter. Although these meta-analyses may not be fully comparable as they

are based on different criteria for the reference plots (study design, method of calculating stocks, detailed land management, scale, etc.), they highlight the considerable uncertainties in the magnitude and direction of change. For instance, the change in SOC when forest is converted to cropland in Don et al (2011) ranges from -80% to +58%. Such uncertainty in the direction of change is explained by the complex interaction between the soil and the vegetation, land management methods (e.g. manure management, crop-fallow succession), erosion processes (Croft et al, 2012), climate and soil properties (Guo and Gifford, 2002) and whether the study design is based on a chronosequence or time series (Fujisaki et al, 2015). Most studies of changes in SOC are unrepresentative of tropical landscapes (Powers et al, 2011) and following Smith et al, (2012), “there is an urgent need for development and implementation of higher tier [tiers 2 and 3] methodologies that can be applied at fine spatial scales (e.g. farm/project/plantation)”

Digital Soil Mapping (DSM) has recently emerged as a new soil science discipline with the introduction of new sensors and new statistical techniques (Mc Bratney et al. 2003). DSM sets out to create soil databases at a given resolution by using field and laboratory observation methods coupled with spatial and non-spatial environmental data (covariates) through quantitative relationships (Boentinger et al, 2010). It has been applied for predicting SOC stocks over a wide range of soils, climates and scales (Minasny et al, 2013). The authors observed that most studies were based on legacy soil data, using internal validation, and that topography, land use/cover and vegetation indices (e.g. NDVI) derived from remotely sensed images were the most widely used covariates. A few studies have been undertaken at field to landscape scale in regions prone to deforestation or soil degradation. Examples include the use of various forms of geostatistics to predict SOC stocks in shifting rainfed rice cultivation regions in Laos (Phachomphon et al, 2010), the use of regression trees combined with topographic, soil and land use information in eucalyptus growing regions in Madagascar (Razakamanarivo et al, 2011) and the use of Landsat images for smallholder agricultural systems in East African countries (Vagen and Winowiecki, 2013). These studies demonstrate how DSM techniques can be used to estimate SOC stocks at fine scale and at a given point in time, but they do not predict or assess changes in SOC stocks.

Soil carbon dynamics can be assessed i) using an empirical approach as illustrated above based on a chronosequence or time series to estimate the effect of land use change (Costa et al, 2013), or ii) using a mechanistic model, with various input factors and parameters that describe the ecological processes and make it possible to handle more sophisticated scenarios in the future. These mechanistic models can be associated with spatial information to create a spatially explicit dynamic model (Easter et al., 2007; Milne et al., 2007). However, these models are based on various assumptions or require a large amount of historical input before they can produce accurate predictions of the changes in SOC stocks over a given landscape.

Static-empirical or partially dynamic models were described by Minasny et al (2013) as a mean of producing quick, cost effective estimates of changes in SOC stocks at appropriate land management scales. However, according to these authors, this approach has not yet been explored. The principle is simple and relies on the basic assumption that some soil factors (covariates), such as topography, are stable over time and that others, such as climate or land use, may change with time. By changing the factors in a calibrated SOC spatial model, it is possible i) to predict changes in order to explore various scenarios, and ii) to evaluate stocks retrospectively to create a time series and assess the effect of land use and land management changes on SOC stocks. This study evaluates this pragmatic approach to assessing potential changes in SOC stocks at landscape scale using an easily-accessed environmental dataset and an ad-hoc field soil inventory.

Madagascar is widely recognized for its high level of biodiversity and endemism (Goodman & Benstead, 2005). The biodiversity is mainly found in its remaining natural tropical forests that cover a wide range of climatic conditions (dry, spiny and humid forests and mangroves, cf figure 1). In the past 50 years, the area of forest in Madagascar has been reduced significantly (Harper et al., 2007) by traditional slash and burn, pasture extension, charcoal production, illegal logging of precious wood, and mining activities, thus affecting biodiversity, biomass, soil and water resources. Despite well-documented local studies of soil dynamics under various forest and agricultural practices (Vagen et al, 2006, Razakamanarivo et al, 2011, Razafimbelo et al, 2010) and the existence of a national carbon map (Grinand et al, 2009), very little is known about i) the levels and distribution of soil organic carbon at regional scale and ii) the changes in soil organic carbon after deforestation at landscape scale. This paper uses the south-east region of Madagascar as a case study to answer the following questions:

- How are the SOC stocks distributed and what are the underlying drivers?
- Can significant changes in SOC stocks be detected using satellite images?
- How are the estimated changes in SOC stocks linked to land cover and land cover change?

The analysis was based on two soil layers (0-30 cm and 0-100 cm) and two climatic regions (tropical humid and dry) in a region highly prone to deforestation (Grinand et al, 2013), over a twenty years period. The methodology applied involved the following steps: soil inventory, soil analysis and carbon stock calculation, soil-landscape factors collection and preparation, spatial modeling of SOC distribution in 2011, spatial prediction of SOC in 1991, SOC change estimation. We finally compared the SOC change map with published deforestation maps in order to assess SOC change following forest to cropland conversion.

2.4 Material and methods

2.4.1 Study Area

The climate in south east Madagascar is governed by the long south-north ridge that divides the humid mountainous and littoral region to the east and the dry, flat region to the west (figure 1), with a narrow transition zone between the two. The boundary between the dry and humid regions is shown in the National Ecological and Forest Inventory (IEFN, 1997) and corresponds to the threshold of around 1000 mm of annual precipitation. The region has acidic basement rocks with dominant ferralsol (54%) in the central and eastern area, Acrisol mainly located in the transition zone (10%) and shallow, sandy lithosol (28%) in the dry western area (Hervieu, 1960). The remaining soils (9%) are calcareous, colluvial and organosol, usually in complex association with the dominant soils in the littoral area.

The area has long been recognized as a major biodiversity hot spot since the creation in 1954 of the Andohahelo National Park which has a high level of endemism. It has also been identified as a major hot spot of deforestation in several studies of forest cover changes (MEFT, 2009; Grinand et al, 2013), mainly in the humid region, with an annual natural forest loss rate of about 1%. According to recent statistics, the population density is 30 people per km² (Vieilledent et al, 2013). Two perimeters were defined: the reference and the study area. The former covers 43 000 ha and was used to calibrate the model. The latter (which includes the reference area) covers 395 000 ha and was used for the spatial/temporal extrapolation. Both areas show similar biophysical conditions (elevation, climate, figure 21).

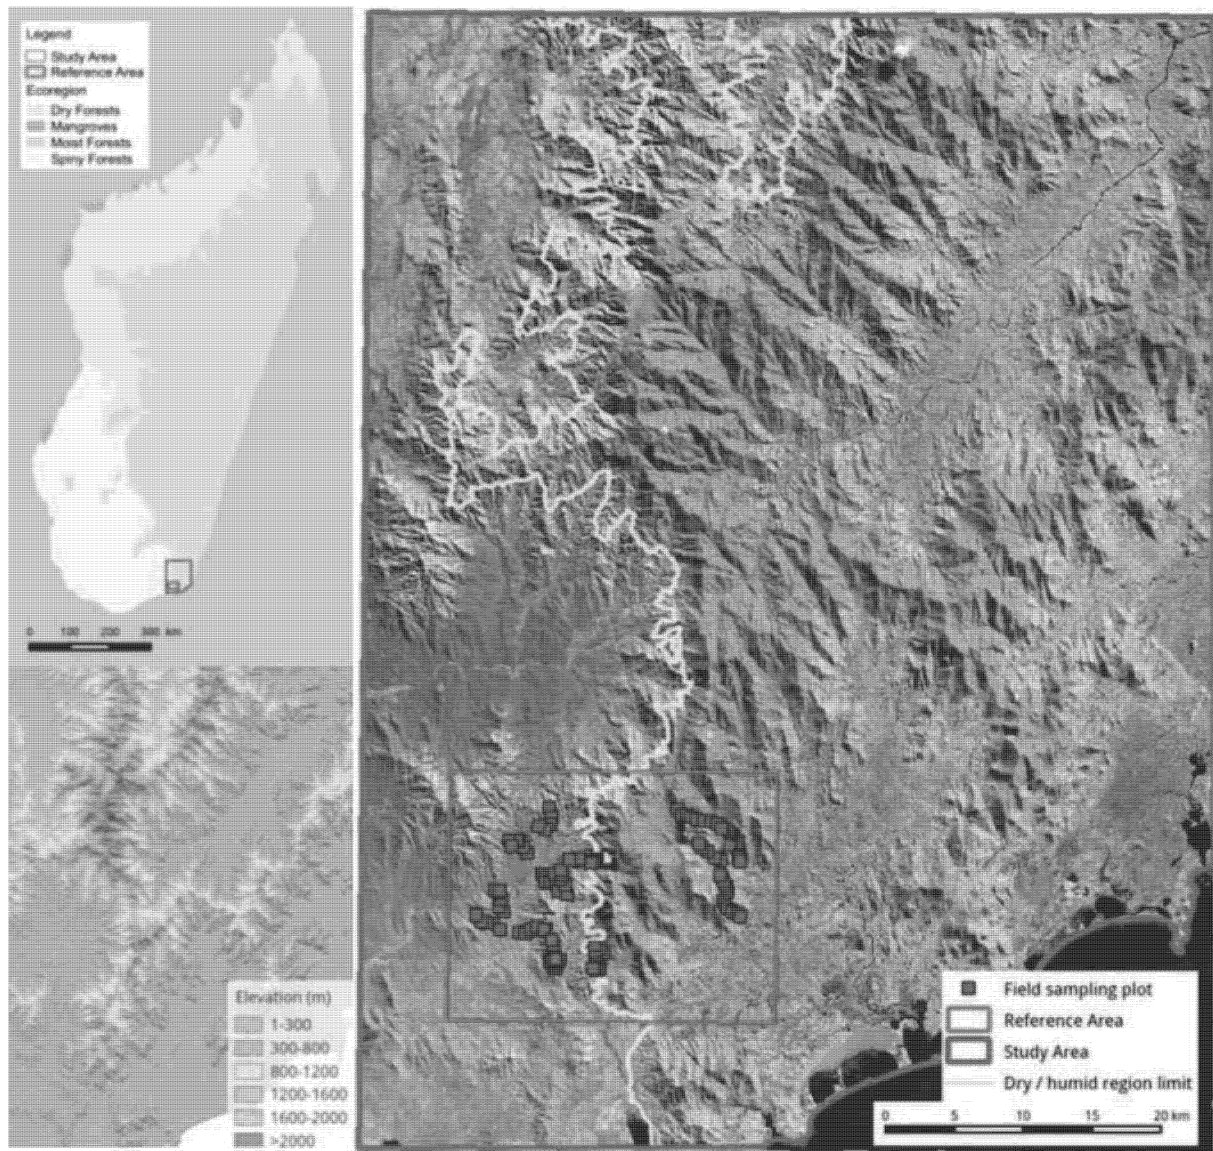


Figure 21 :Location of the study and reference areas with both dry and humid climates. The Landsat image on the right was acquired on July 5 2011. The ecoregion map (top left) was extracted from the Global 200 World Wide Fund project (http://en.wikipedia.org/wiki/Global_200). The boundary between the dry and humid regions (yellow line on map on right) was extracted from (IEFN, 1997). The elevation map (bottom left) was extracted from the ASTER Global Digital Elevation Map (2011).

2.4.2 Field data collection and soil analysis

.2.4.2.1 Soil inventory

The first step was to collect data and prepare a harmonized dataset of soil carbon stocks for the 0-30 cm and 0-100 cm soil layers. A field survey of 95 10 x 10 m plots on various types of stable land cover (intact forest, crop, pasture) was carried out in 2010 based on topographical transects in the reference area. Soil core samples were taken at four points evenly spaced at 10 m and combined. Five layers (0-10, 10-20, 20-30, 50-60 and 90-100 cm) were sampled.

Additional samples were collected to estimate the bulk density of the first three layers, at one corner of the plot and using the cylinder method.

.2.4.2.2 Laboratory and spectral analysis

The samples were taken to the laboratory in Antananarivo (Laboratoire des Radio-Isotopes) for analysis. The SOC content of a random selection of 138 samples was analyzed using the wet oxidation method (Wakley Black) and the entire set of samples ($n=440$) was scanned using mid infrared spectrometry (MIRS). Spectrometry analysis and chemiometric techniques are used routinely to give accurate, cost-effective estimates of many soil properties (Shepherd and Walsh, 2002, Viscarra-Rossel et al, 2006) including SOC (McCarty et al, 2002, Grinand et al, 2010) and has already been used in Madagascar (Rabenarivo et al, 2013). Sample reflectance in the mid-IR range was measured between 4000 cm^{-1} and 400 cm^{-1} (i.e. 2500 nm and 25,000 nm, respectively) at 3.86 cm^{-1} intervals with a Nicolet 6700 FT-IR spectrophotometer. Following Rabenarivo et al (2013) the scan was performed on a 12.6 mm^2 area of a 0.5 g sub-sample (0.2 mm ground, oven-dried at 40°C) packed in a well of an 18-well plate. Both spectrum ends were discarded due to noise and only the range $3926\text{--}783\text{ cm}^{-1}$ was considered, yielding 816 data points per spectrum.

.2.4.2.3 Carbon content spectral model

We applied two standards pretreatment procedure (mean average of 5 points followed by Standard Normal Variate transform - SNV) to reduce the noise effect (Viscarra-Rossel et al, 2006; Rabenarivo et al, 2013). Then, a local prediction model was developed using partial least square regression (PLSR) available in the “pls” R package based on the 138 laboratory carbon measurement and MIR reflectance. We applied a ten fold cross validation procedure to estimate the optimal number of component (minimum of the root mean square error of prediction - RMSEP) and calculate validation metrics (RMSEP and R^2). We obtained a RMSEP of 5.01 g.kg^{-1} and an R^2 of 0.82 for the cross-validated predictions. The full model was then used to predict the carbon concentration of the 302 samples with no laboratory measurement.

.2.4.2.4 SOC stock calculation for 30 and 100 cm soil layer

A complete soil dataset was obtained for the 0-30 cm soil layer but only sparse estimates for the 0-100 cm layer owing to cost and labor constraints. However, as the carbon content at depth is of great interest because of its large carbon stock and because it can be used for hydrological modeling (Minasny et al, 2013), it was studied in greater detail. Local pedotransfer vertical functions were developed to estimate the bulk density and SOC at unsampled locations in the profile down to 1 m. Splines were used to estimate SOC and rock fragments and linear logarithmic regression as a function of depth was used to estimate the

bulk density. This gave estimates at seven points along the vertical profile for each parameter. The vertical profile of each plot was examined visually and five plots with outlier values were excluded. The harmonized soil dataset and calculated SOC stocks are summarized in tableau 8.

Tableau 8 : Soil inventory summary statistics. *n* represent the number of soil samples for the three soil variables and number of plots for SOC 30 (soil organic carbon stocks for the top 30 cm soil layer) and SOC 100 (soil organic carbon stocks for the top 100 cm soil layer). Min. minimum, max, maximum, s.d. standard deviation.

Climate region	Soil variable	Unit	n	mean	min	max	s.d.
dry	bulk density	g.cm ⁻³	314	1,0	0,7	1,2	0,1
	coarse fragment	%	314	12,0	0,0	39,9	7,1
	organic carbon	g.kg ⁻¹	314	10,8	2,2	47,0	8,3
	SOC30	MgC.ha ⁻¹	45	38,0	12,6	72,1	15,4
	SOC100	MgC.ha ⁻¹	45	80,5	35,2	141,1	27,2
humid	bulk density	g.cm ⁻³	315	1,0	0,7	1,2	0,1
	coarse fragment	%	315	5,0	0,0	20,7	4,5
	organic carbon	g.kg ⁻¹	315	17,7	2,3	87,3	14,4
	SOC30	MgC.ha ⁻¹	45	69,2	37,7	131,1	25,4
	SOC100	MgC.ha ⁻¹	45	135,5	75,1	210,5	37,9

2.4.3 Factors used in the SOC extrapolation model

The second step was to collect and define relevant spatial predictors of SOC stock distribution. There is a well established group of soil-landscape factors that are commonly used in DSM applications (McBratney et al 2003, Grunwald et al, 2009). A set of 20 soil-landscape factors was compiled (tableau 9) from easily-accessed sources.

A freely available Landsat image (<http://usgs.earthexplorer.org>), acquired on June 5, 2011, was selected because of i) its date that was close to the inventory date, ii) it is available as a Global Land Survey (GLS) product (Gutman et al, 2005) which are made of composite of Landsat TM and ETM+ and iii) the cloud cover was delimited and low. A second GLS image acquired on July 24, 1991 was used for extrapolation into the past (see 2.5). The datasets have the reflectance of the land surface in the visible and near infra-red regions which is widely used to indicate the primary and ecological productivity. The reflectance in the middle and thermal infrared bands depends mostly on the soil properties (Mulder et al, 2011, Croft et al, 2012).

Local geomorphological factors were derived at 30 m resolution from the ASTER Global Digital Elevation Map (2011) using standard Geographical Information System (GIS) software (QGIS, SAGA and Grass). These factors describe the physical landscape (slope, aspect, convexity) and represent ecological processes such as potential water storage downslope (wetness index), erosion potential (length of slope) and insolation.

Two climatic factors, annual precipitation and mean annual temperature, were added from the WorldClim database (Hijmans, et al, 2005) as they are known to influence soil carbon distribution and soil carbon change after land use change (Guo and Gifford, 2002) and gamma radiometric datasets were obtained from the Ministry of Energy and Mines and explore the potential of K, U and Th relative concentration in explaining SOC stock distribution. Gamma radiometrics provide useful information for soil organic mapping, as a proxy of water retention and clay content (Rawlins et al, 2009) and even more interestingly for characterising erosional, depositional and weathering processes (Wilford et al, 2006). From these datasets, the concentrations of potassium (K), uranium (U) and thorium (Th) were selected as factors. These datasets are at 100 m resolution. Given that spatial factors have a wide range of ground resolutions and that the aim was to detect SOC stock change from field scale upwards, a working grid of 30 m was used. Climatic factors were fitted to the 30 m grid by using cubic splines interpolation and the gamma radiometric dataset factors were resampled using the nearest neighbors technique.

Tableau 9 : *Spatial soil factor database and results of correlation with SOC stocks for 0-30 cm (SOC30) and 0-100 cm (SOC100) soil layers. * indicates that the p-value (Pearson's test) is less than 0.01 for the correlation between the landscape factor and the SOC stock value.*

Category	Soil-Landscape factor	Name	Unit	Correlation	
				SOC30	SOC100
Soil & Vegetation	Landsat band 1 (blue)	B1	reflectance	-0,47 *	-0,39 *
	Landsat band 2 (green)	B2	reflectance	-0,42 *	-0,34 *
	Landsat band 3 (red)	B3	reflectance	-0,41 *	-0,35 *
	Landsat band 4 (near infra red)	B4	reflectance	-0,07	-0,01
	Landsat band 5 (middle infra red)	B5	reflectance	-0,37 *	-0,29 *
	Landsat band 6 (thermal infra red)	B6	reflectance	-0,25 *	-0,20 *
	Landsat band 7 (middle infra red)	B7	reflectance	-0,38 *	-0,31 *
Geomorphology	Elevation	ALT	meter	0,35 *	0,27 *
	Slope	SLP	degree	0,21 *	0,19 *
	Aspect	ASP	degree	-0,02	-0,07
	Valley depth	VAH	meter	0,35 *	0,37 *
	Ridge height	RID	meter	0,20 *	0,14 *
	Topographic wetness index	TWI	-	0,11	0,13
	Insolation	NRJ	watt.m ⁻²	-0,24 *	-0,30 *

Climate	Length of the slope	LS	meter	0,27 *	0,26 *
	Mean annual precipitation	MAP	meter	0,47 *	0,50 *
	Mean annual temperature	MAT	°C	-0,48 *	-0,41 *
Parental material	Potassium	K	-	0,07	0,02
	Uranium	U	-	0,04	-0,05
	Thorium	TH	-	0,20 *	0,14 *

2.4. Calibration of the SOC spatial model

The next step aimed to build a multivariate model to explain the spatial distribution of SOC as a function of the covariates. Firstly, a zone of 10 m around the center point of the plot was used to represent the ground sampling location. These zones were intersected with the 30 m spatial covariate grid, creating a total of 195 data points for the calibration dataset, as some plots intersected more than one of the 30 meter grid cells. Then, an ensemble machine learning approach was applied using the “Random Forests” algorithm (Breiman et al, 2001). This algorithm has been shown to be useful for complex and non-linear ecological applications such as soil organic carbon mapping (Grimm et al, 2008, Vagen et Winowiecki, 2013, Screenivas et al, 2014, Wiesmeier et al, 2011) and above-ground biomass mapping (le Maire et al, 2011a, Baccini et al, 2012, Asner et al, 2012, Vieilledent et al, 2016). A 10 fold cross validation procedure was applied to evaluate the means and standard deviations. Standard regression quality indices, root mean square error (RMSE, absolute and in % relative to the mean) and R^2 , bias and ratio of performance to deviation (RPD) were produced for the cross-validation dataset. This validation procedure appeared to be a good compromise for providing realistic values between optimistic methods such as the out-of-the-bag, leave-one-out and standalone test-set procedures and difficult to achieve, external or geographically distant validation approaches, which were not possible in this case. This procedure was already used in other digital soil mapping studies (Grimm et al, 2008, Razakamanarivo et al, 2011). Further calibration tests were performed including change of covariates dataset and change in randomForest parameters (mtry, ntree). The former was based on our expert local knowledge and the result of the relative importance of the factor measured by the randomForests algorithm (NodePurity). NodePurity is an importance index calculated by random Forest, that measure the change in residual sum of squares from splitting on the variable, averaged over all trees. Several linear models were compared with the random forest model using the same validation procedure, but these always produced poorer results (data not shown). All statistical tasks described above and below were performed using R-statistics version 3.02 (R Development Core Team, 2005), the randomForest package version 4.6-10 (Liaw et Wiener, 2014) and raster package version 2.3-40 (Hijmans et al, 2015).

2.4.4 Spatial prediction over the study area

Once the model had been calibrated for the reference area (43,000 ha), it was applied to predict the SOC over the entire study area (395,000 ha). This involved considering the representativeness of the reference area (Lagacherie et al, 2001) and the applicability of the model, with a known level of accuracy, at cell scale (Grinand et al, 2008). There is potentially many source of uncertainty: i) in the calculation of SOC stocks, such as sampling errors (e.g. depth), laboratory analysis, pedotransfer functions (Goidts et al, 2009), and ii) in the spatial modeling, such as approximations for the raw covariates (e.g. slope derived from 30 m GDEM, geometrical distortion of the satellite image) and standard errors of the model parameters and residuals. Considerable effort is required to take into account all sources of uncertainty, using error propagation techniques, which rely on assumptions for estimating the accuracy at cell level. This study used model averaging techniques to estimate accuracy at cell level. This implied producing 10 carbon maps using 10 different models set using a random bootstrap selection of 70% of the calibration dataset. This technique has been applied in previous works on biomass mapping (Casey et al, 2012) and is considered to provide an integrated estimate of the uncertainty from both sampling and modeling. Finally, the carbon maps were combined to produce the mean (SOCmean-2011) and standard deviation (SOCsd-2011) from the 10 bootstrap maps.

2.4.5 Prediction of SOC stocks in 1991

In the final step, the covariates were split into stable and dynamic sets. Over the 20 year analysis period, only the soil-vegetation covariates (Table 2) derived from Landsat images were considered to be dynamic. The Landsat image acquired on July 24, 1991 was selected using the same geometrical and cloud cover criteria as for the 2011 image. The 1991 image could not be used directly since reflectance changes may arise from atmospheric conditions, sensor properties or acquisition geometry, and not from changes in soil-vegetation status. These image-related changes apply to the entire image, which was confirmed in this case by pair-wise band comparison, revealing small reflectance variations in the overall image statistics (min, max, standard deviation, quantile). Invariant target detection is a simple method used to correct for these changes. Some pixels are considered to have constant characteristics over time, and so changes in their reflectance observed from satellites is considered to come from the atmosphere, geometry of acquisition, and sensor properties. If there are a number of these invariant pixels, a correction equation can be calibrated, which is generally linear (gain, offset) (el Hadjj, 2008). In this case, no clear invariant targets were found, and so it was decided to use all the points in the images, as described by le Maire et al (2011b), assuming that i) acquisition-related changes affect the entire image, ii) a large majority of the pixels will not have large intrinsic reflectance changes (even if not totally

“invariant”). The correction procedure simplified to the calibration of a band-specific linear regression between the 1991 and 2011 images, followed to the application of the obtained gain and offset. To ensure the robustness of this regression, pixel-to-pixel regressions were checked to ensure that they gave the same gain and offset parameters for different pixel resolutions (results not shown). The SOC stock distribution in 1991 was then predicted by applying the same procedure and model as for 2011 (previous section 2.5), i.e. using bootstrap model averaging to produce mean (SOCmean-1991) and standard deviation (SOCsd-1991) maps.

2.4.6 Detection of changes in soil carbon stocks

Potential SOC stock change maps (SOC1991-2011) were produced by subtracting SOCmean-1991 from SOCmean-2011, and dividing by SOCmean-1991 to determine the relative change (SOC1991-2011-%). However, maps of SOC stock changes (0-30 cm and 0-100 cm soil layers) included errors from the two carbon maps which needed to be removed before significant SOC changes can be determined. Three post-processing steps were carried out. To address extrapolation issues, thresholds on minimum and maximum reflectance values obtained from the calibration dataset were applied to remove all the values outside this range for both 1991 and 2011.. Topographical shadows were removed by applying threshold values to the insolation. A simulated map of direct insolation at acquisition time was used to identify cells with no direct insolation and exclude these from the analysis. Finally, attention was paid to very small changes that can represent a large variation in stock at large scale but that do not represent significant change at the pixel level, using a minimum detectable difference (MDD) approach (Post et al, 2001 and Garten and Wulfschleger, 1999). The MDD is defined as the “smallest difference that can be detected between two mean soil organic carbon inventories with a certain level of confidence given the average variance and sample size”. Considering that the sample size in our study was the number of cells (5.3 million for the study area), the formula used by the authors would produce a very low MDD, and so this approach was modified. MDD was defined here, for each cell, as the maximum standard deviation of either SOCsd-2011 or SOCsd-1991. If the absolute soil carbon change (SOC1991-2011) was below the MDD, no change was assumed (zero value).

2.5 Results

2.5.1 SOC stock plot dataset

In the dry region, the SOC stocks ranged from 38 to 72 MgC.ha⁻¹ for the 30 cm soil layer, and 81 to 141 MgC.ha⁻¹ for the 100 cm soil layer. In the humid region, the range was 70 to 131 MgC.ha⁻¹ for the 30 cm soil layer and 139 to 296 MgC.ha⁻¹ for the 100 cm soil layer. The

coefficient of variation was slightly higher for the 30 cm soil layer (39%) than for the 100 cm soil layer (31%). Overall, the SOC in the 30 cm soil layer accounted for half (49%) of the SOC stored in the 0-100 cm soil layer. There were also considerable differences in the SOC content and rock fragment content between these two regions.

2.5.2 Model accuracy assessment

We obtained R^2 of 0.72 for the 0-30 cm soil layer and 0.69 for the 0-100 cm soil layer (tableau 10). RMSE were 14 and 23 MgC.ha⁻¹ representing 27% and 23% of the mean. R^2 ranged from 0.49 to 0.91 for the 0-30 cm soil layer and 0.43 to 0.88 for the 0-100 cm soil layer. This slight reduction in performance with depth is not surprising and confirmed previous reports (Malone et al, 2009). Reasons may be the use of a pedotransfer function (splines) to estimate soil properties (bulk density, carbon content, rock fragment) along the 0-100 cm soil profile and the lack of predictors for soil properties below ground. Despite clear underestimation of high SOC values for some validation points (Figure 2a), the overall model shows only a slight bias (0.5 and 0.3 MgC.ha⁻¹).

Tableau 10 : Averaged validation indices for the 10 cross-validation runs. Minimum and maximum values recorded are in brackets.

Soil layer (cm)	R^2	RMSE (MgC.ha ⁻¹)	RMSE (%)	Bias (MgC.ha ⁻¹)	RPD
0-30	0,72	14,4	26	0,5	1,97
	[0.46, 0.91]	[9.5, 18.3]	[18, 34]	[-4.7, 2.9]	[1.38, 3]
0-100	0,69	23,5	22	0,3	1,88
	[0.43, 0.88]	[17.6, 31.5]	[17, 27]	[-8.5, 7.8]	[1.34, 2.5]

2.5.3 Importance of soil carbon controlling factors

The importance of each variable was studied i) by analysing pair-wise correlation of SOC stocks with the covariates and ii) by analyzing the internal randomForest variable importance metric.

Pair-wise correlation between SOC stocks and spatial covariates showed interesting patterns (tableau 9). Nine of the twenty spatial covariates had correlation (r) values above 0.3, including visible and mid infra-red bands (1,2,3,5,7), valley depth and the two climatic variables (precipitation and temperature). Near infra-red was weakly correlated with SOC

stocks (0.07), and the thorium relative concentration was relatively high (0.20) for the top soil layer. Similar trends were observed for both the 0-30 cm and 0-100 cm soil layers, with almost systematically lower correlations for the 0-100 cm soil layer.

The relative importance of the soil-landscape factors was further analyzed by calculating the NodePurity index (figure 22 b). Again, similar patterns were found for both soil layers. Precipitation and temperature both explain regional SOC patterns to a far greater extent than other factors. The factors obtained from gamma radiometry, especially thorium surface concentration, appeared to have a significant influence on SOC distribution. Finally, with similar relative importance, the visible (bands 1 and 3) and mid infra-red (band 7) reflectance and some topographic variables (valley height, altitude) stand out from the other factors. The SOC 30 and 100 models differ with temperature being less important and thorium being more important for the 0-100 cm soil layer.

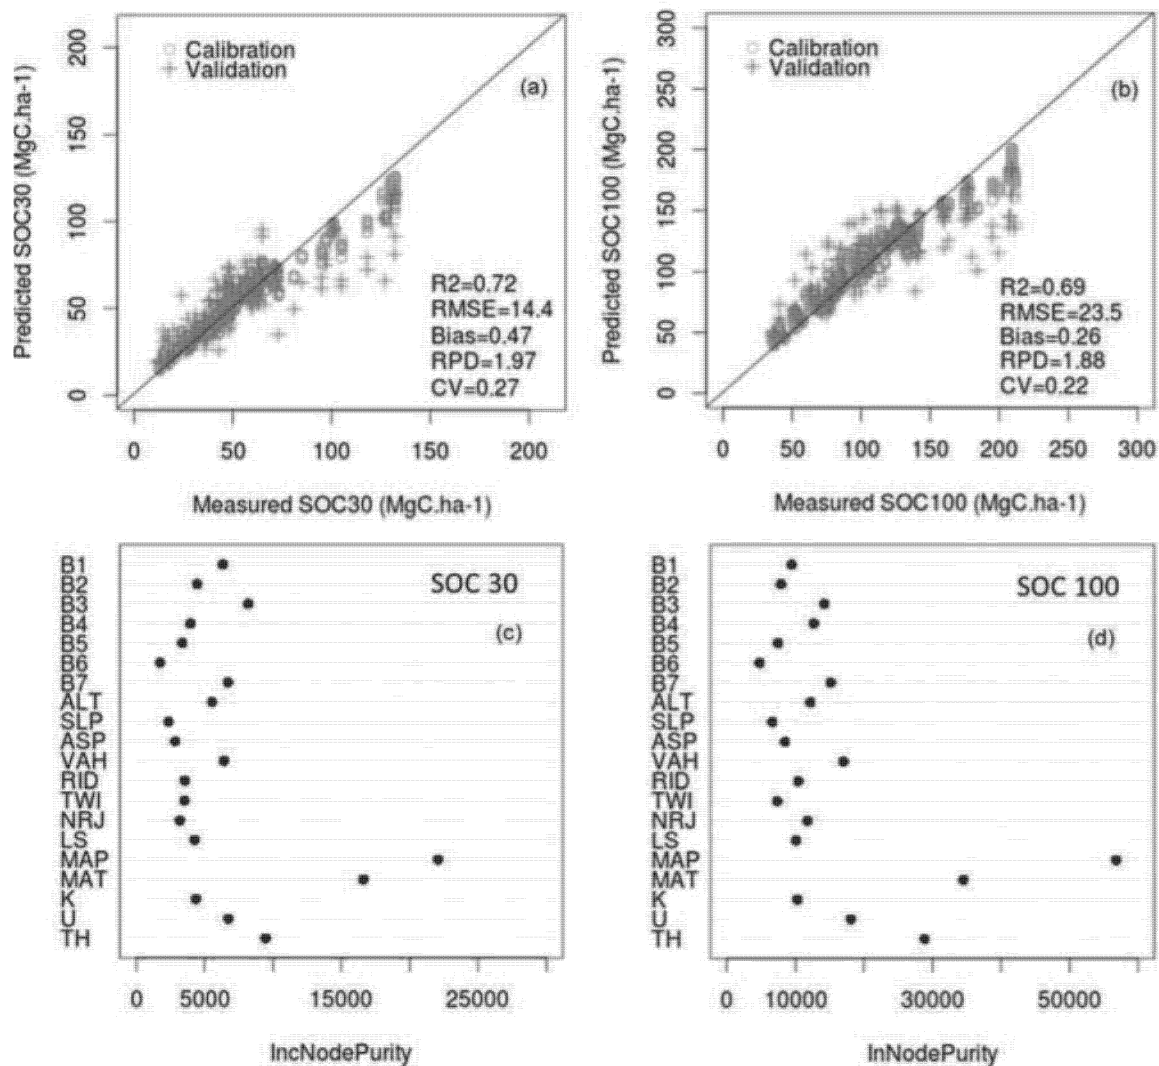


Figure 22 : Predicted vs Measured plot for calibration and validation datasets for SOC 0-30cm soil layer (a) and 0-100 cm (b) soil layer and average relative importance of

variables for both spatial models (c and d). Variable names and description are given in Table 2. The accuracy measurements (R², RMSE, Bias, RPD, CV) are those calculated for the validation dataset (see also table 3).

2.5.4 Spatio-temporal estimates of SOC stocks

The prediction of SOC stocks in the 0-30 and 0-100 cm soil layers, at a 30 m resolution over the entire study area for 1991 and 2011, is shown in figure 23.

Post processing steps to remove topographic shadows and out-of-reflectance-range pixels reduced the study area from 474,661 ha to 351,117 ha for the 2011 map and 256,000 ha for the 1991 map. Shadows accounted for 40,467 ha (8.5%) and out-of-reflectance-range pixels accounted for 83,077 ha (17.5%) for 2011 and 178,194 ha (37.5%) for 1991. The areas eliminated were mainly in areas with steep slopes in both the dry and humid regions. The northern part of the study area, wetlands (not sampled) and some densely forested areas were excluded as the soil and vegetation conditions were different from the reference area. The small amount of cloud cover was also removed during post processing.

The SOC stock maps produced clear patterns. Firstly, an east-west gradient from high to low SOC stock is visible, influenced by the precipitation gradient. Secondly, the temperature and altitude, which are highly correlated factors ($r=0.89$), are also responsible for great variations, with low stocks in low altitude, warmer regions and higher stocks in high altitude, cooler regions. Thirdly, the land cover and topographical effects on SOC change are less pronounced within the landscape. Nevertheless, changes can be seen on the edge of the tropical humid forest as well as in cultivated plots on the slopes (enlargement in figure 23). Generally, both 1991 and 2011 maps show the same overall pattern (figure 23 and tableau 11). We observed an average of 25 MgC.ha⁻¹ difference between forest and crop / savannah in the humid area (87.4 and 61.4 MgC.ha⁻¹ respectively in 2011). Carbon stocks were estimated to be 5 to 7 MgC.ha⁻¹ lower in forests than in crop / savannah in dry regions, but this difference was of the same order of magnitude of the standard deviation (10 MgC.ha⁻¹).

Tableau 11 : *Estimated SOC stocks for forest and crop / savannah land cover for the 0-30 cm and 0-100 cm soil layers taken from 1991 and 2011 carbon maps.*

Climatic region	Land cover (2010)	Area (ha)	SOC stock 1991 (MgC.ha ⁻¹)				SOC stock 2011 (MgC.ha ⁻¹)			
			30 cm		100 cm		30 cm		100 cm	
			mean	s.d.	mean	s.d.	mean	s.d.	mean	s.d.
Humid	Forest	116 998	83,2	11,5	145,1	12,4	87,0	10,4	146,3	11,6
	Crop and savannah	194 162	61,0	7,2	125,5	10,1	61,0	7,0	125,4	9,7
Dry	Forest	766	39,4	9,4	83,1	14,7	40,1	9,7	84,2	15,3
	Crop and savannah	93 493	45,2	10,7	92,2	16,3	46,8	10,5	94,7	16,3




Figure 23 : *SOC (0-100 cm) maps produced for 1991 and 2011 for the entire study area and an enlargement of a mountainous and forested landscape (A) associated with shifting cultivation plots (B) and undulating grassland valley (C).*

2.5.5 Detecting changes in SOC stocks at regional scale

Applying the MDD threshold to the SOC change maps identified 47,287 ha (10%) with significant SOC changes for 0-30 cm soil layer, and 38,376 ha (8.1%) for the 0-100 cm soil layer. The remaining areas of 173,248 ha (36.4%) and 182,159 ha (38.3%) was set to zero change (no significant changes). This map is shown in figure 24.

In the humid region, there was a large area with significant potential soil carbon loss around the forest edges, in known deforestation areas (see section 3.6) as well as outside known deforestation areas. For the 0-30 cm soil layer, the largest reduction in stocks (1991) was 40.8% and the largest increase was 58.3%. The 1% and 99% quantiles were at -23% and +13% (tableau 12).

In the dry region, for the 0-30 cm soil layer, the largest reduction in stocks was 42.1% and largest increase was 83.4%, and the 1% and 99% quantiles were at -12.9% and +15.4%. The changes in SOC for the 0-100 cm soil layer were always lower than for the 0-30 cm soil layer, from approximately -12% to +12% for both regions (1% and 99% quantiles).

At the landscape scale, in the humid region, there was a significant increase in SOC stocks in forested areas and in small patches of the valleys and downhill slopes. In the dry region, the SOC distribution patterns are less clear with generally a small increase in stocks and some distinct major reductions. There was no particular trend in grassland areas. The three dimensional view (figure 24) highlights the locations of the changes in SOC stocks within the landscape. A mosaic of cropland and fallow (shifting cultivation) on the slopes was particularly subject to reduction in SOC stocks of more than 10% in 20 years. Larger reductions (between 15% and 40%) could be seen in the middle to top slopes, reductions of around 10% could be seen downhill but there were no reductions in the valleys. SOC stocks increased in other small areas of land spread over the hills and in the valleys.

Analyzing the correlation between the changes in SOC stocks and the initial stocks (figure 25) showed that the highest potential reduction in the humid region was correlated with the highest initial SOC stocks. The highest potential increase was for areas with average stocks. In the dry region, the trends were similar, but less pronounced. The highest potential increase, however, appeared to be for the lowest initial SOC stocks.




Figure 24 : Potential SOC change map 1991-2011 for the 0-30 cm and 0-100 cm soil layers and a 3D landscape view. The area in white represents no significant change and no data is available for the areas in black. The blue polyline encloses the areas subject to deforestation between 1990 and 2010 (MEFT, 2009; Grinand et al, 2013).

Tableau 12 : Potential changes in SOC stocks over the study area. “n” is the number of observations/pixels.

Climate region	Soil layer (cm)	n	SOC stock change (%) quantile values								
			Min	1%	5%	25%	50%	75%	95%	99%	Max
Humid	0-30	1 473 532	-40,8	-23,1	-11,8	0	0	0	6,4	13,7	58,3
	0-100	1 473 532	-28,4	-12,6	-6,3	0	0	0	3,6	7,8	33,3
Dry	0-30	970 710	-42,1	-12,9	0	0	0	0	6,0	15,4	83,4
	0-100	970 710	-28,4	-7,9	-2,9	0	0	0	4,6	12,4	36,6




Figure 25 : Potential changes in SOC stocks estimated as a function of the initial stocks over the study area. Each graph were created using 100 000 observations/pixels randomly selected. Colors indicate density of observations/pixels (from white-blue to green, red).

2.5.6 Changes in SOC stocks in deforested areas

SOC stocks change maps were compared with already published maps that located deforestation for three periods: 1990-2000, 2000-2005 and 2005-2010 (MEFT, 2009; Grinand et al, 2013). The analysis was based on 8,326 and 50,399 cells in the dry and humid regions respectively (tableau 13). In the humid region, the change in SOC for deforested areas was -10.7% for the 0-30 cm and -5.2% for the 0-100 cm soil layer. In the dry region, the net change of SOC in deforested areas was close to zero (-0.1%, -0.33%) for the 0-30 cm and 0-100 cm soil layers respectively.

The changes in SOC for areas deforested over three periods (1990-2000, 2000-2005, 2005-2010) were calculated only for the 0-30 cm layer (figure 26). The average potential reductions were 9.6%, 10.7% and 11.7% respectively in each of these deforestation periods..

Tableau 13 : Changes in SOC stocks for areas deforest in various periods. “n” is the number of SOC change observations (pixels). 5%q and 95%q are the 5% and 95% quantiles. S.D. is the standard deviation.

Climatic region	Soil layer (cm)	Period of forest to cropland conversion	n	Absolute change of SOC (MgC.ha ⁻¹)				Relative change of SOC (%)				Average stock prior to conversion (MgC.ha ⁻¹)
				Mean	S.D.	5%q	95%q	Mean	S.D.	5%q	95%q	
Dry	0-30	1990-2010	8326	-0,2	2,0	-3,5	2,1	-0,1	3,8	-6,3	5,3	38,9
	0-100	1990-2010	8326	-0,3	2,7	-4,2	4,0	-0,3	2,9	-4,9	4,7	83,2
Humid	0-30	1990-2010	50399	-8,8	9,0	-27,0	0,0	-10,7	9,9	-29,1	0,0	75,7
	0-100	1990-2010	50399	-7,6	8,9	-25,0	0,0	-5,2	5,9	-16,3	0,0	140,3




Figure 26 : SOC change (0-30 cm – humid region) between 1991 and 2011 for various deforestation periods. Each graph were created using 15 000 observations/pixels randomly selected. Colors indicate density of observations/pixels (from white-blue to green, red).

2.6 Discussion

2.6.1 How the SOC stocks distributed and what are the underlying drivers?

First, at plot scale and for the 0-30 cm soil layer, we recorded an average of 69.2 MgC.ha⁻¹ and 38 MgC.ha⁻¹. These figures are similar to those estimated by Grinand et al, (2009) for the two dominant soils in Madagascar: the Ferralsol (61,3 MgC.ha⁻¹) and Oxisol (33,6 MgC.ha⁻¹). These observations reflect the discrepancies in dominant soil types found in the two ecoregions (see section 2.1) and ecological processes (less primary biomass productivity inputs and increasing mineralization with increasing temperature in the dry region).

Then, the regression quality indices of the soil-landscape model (R^2 of 0.72 and 0.69) were comparable with other regional and fine-scale studies. Adhikari et al (2014) reported R^2 values ranging from 0.23 to 0.63 in Denmark, Malone et al (2009) reported R^2 of 0.44 in Australia, Vagen and Winowiecki (2013) reported R^2 of 0.65 in Ethiopia and Wiesmeier et al (2011) reported R^2 of 0.74 in China. The slight underestimation of high SOC values may be explained by an under representation of these values in the training dataset. However, this should not affect the estimated changes in SOC stocks as the differences between SOC stocks were computed. The most important explanatory variables in the model underlined the dominant role of climate on SOC distribution. Small changes in future climate trends will have a considerable effect on the storage of soil carbon. This is an important finding for predicting the effect of global changes on future SOC stocks. The role of climate on SOC storage is not yet fully understood, but there is a consensus in the literature that, as total annual rainfall increases, increased biomass production will increase SOC stocks while higher mean annual temperatures may increase mineralisation, thus decreasing SOC stocks (Chaplot et al, 2010). However, laboratory experiments do not always confirm this increased SOC turnover (Hamdi et al, 2013).

Secondly, gamma radiometry, used as a proxy of the parental material, was an unexpectedly important predictor of SOC stocks. The literature has shown gamma radiometry to be a proxy of water retention and clay content (Rawlins et al, 2009) and more generally for characterizing erosion, deposition and weathering processes (Wilford et al, 2006). However, one of the very few studies on soil carbon mapping using gamma radiometry reported that, of the three elements, K was the most important (Malone et al, 2009). So far as we are aware, no studies have been carried out on Th as a strong predictor of SOC stocks. Wilford et al (2006) explained that Th and U are associated with more stable weathered constituents in the soil profile unlike K which is easily displaced during weathering and leaching. Besides, during weathering, Th and U are “readily absorbed onto clay minerals, oxides (Fe and Al) and organic matter” which may explain the high importance of Th in our model. This is a

significant finding as Madagascar has a high coverage of gamma radiometry images which may considerably improve soil inventories or mapping programs.

Thirdly, soil-vegetation and topographic factors are significantly correlated with SOC but to a lesser extent in the model. The magnitude of spatial variation of those factors at local scale is high which explain a more complex and not homogeneous relationship over the study area.

2.6.2 Can significant changes in SOC stocks be detected using satellite images?

This study explored the use of archive satellite images to estimate changes in SOC stocks at fine scale within a region. The results show a wide range of changes, between approximately 40% to +40% of the initial stocks (tableau 12) over a twenty year period. The approach is empirical based on two points in time and was referred to as potential change since the soils at the two dates cannot be considered to be at equilibrium. This raises the question of whether this approach is competitive with other well-known techniques and whether the results are accurate.

The spatio-temporal extrapolation issues are addressed by focusing on accuracy, the key aspect being ensuring the validity of the predictions. The post-processing controls reduced the area under investigation by about half, especially far from the reference area. This was to be expected as the soil conditions and environment are variable. Topographic shadows covered a significant area as well as zones such as wetland which were not sampled. One way to overcome these limitations and increase the area under study is to increase the number of points sampled. Furthermore, large areas of forest in the 1991 image were removed despite pair-wise reflectance calibration. This may be because the soil moisture or phenology conditions were different from those in the 2011 image. A top-of-the-canopy atmospheric correction may be used. However, there is no unique and robust atmospheric correction and there may still be temporal bias with our methodology, especially in local areas of the image if there are changes in atmospheric conditions within the study area. Setting the change to non-significant value using MDD criteria minimizes small but potentially very wide area changes and improves the statistical strength. The estimated changes in SOC stocks cannot be validated directly since no past data are available. Indirectly, we observed that the average SOC stocks on stable land cover (tableau 11) were similar which suggests that there is no obvious bias in our estimates.

Other empirical SOC stock change evaluation methods, such as point sampling based on either chronosequences or time series, suffer from low spatial representativeness over a country, or even over a landscape. They require an extensive soil monitoring system (Morvan et al, 2008) to be set up, which is rarely possible, or would require many years to provide

useful and reliable data.. Simulating changes in SOC stocks using dynamic models suffers from the same spatial limitations. Our spatial assessments of potential changes in SOC stocks makes it possible to produce thousands or millions georeferenced observations of SOC change (pixels) owever, the results suffer from a lack of knowledge on the effects of land use or land management. Hypotheses can be made concerning explanatory factors that cause changes in SOC stocks but these need to be verified in the field. If they are confirmed, this approach may be adapted to take account of subtle effects that cannot be properly addressed by mechanistic models (e.g. forest degradation, natural regeneration). One way to explain changes in SOC stocks would be to perform inverse modeling, using spatially explicit factors. This study only attempted to analyze the effect of deforestation and initial SOC stocks. This empirical approach is a useful initial and cost-effective method to gain knowledge on historical soil dynamics.

2.6.3 How are the estimated changes in SOC stocks linked to land cover and changes in land cover?

The maps of changes in SOC stocks in the 0-30 cm and 0-100 cm soil layers were analyzed for various land covers and land cover changes. The differences between forest and crop / savannah stable land cover in the humid region were 20 to 25 MgC.ha⁻¹ (tableau 11). Surprisingly, in the dry region, the average SOC stocks were slightly higher in the crop / savannah areas compared to those estimated in the dry forest. One possible explanation is that the dry area derived from the ecological map include a mix of humid and dry ecophysiological conditons, , thus resulting in less distinct pattern in the dry region. Local knowledge would be required to delineate a transition zone between humid and the dry region. i

At landscape scale, there are areas of SOC stock reductions for crop / savannah land cover on slopes. These may be associated with crop practices as well as ongoing erosion. There are some stock reductions in forested areas, which may be caused by degradation but this appears to be limited. However, there are large areas of SOC stock increases in forested areas in both humid and dry regions. This may be the result of a reduction in the use of wood products related to security issues over recent years. Small patches of SOC stock increases in the valleys and in the plain may be associated with fallow or plantation. These hypotheses should be confirmed by a detailed survey of historical practices.

In the deforested areas in the humid region, there was an estimated average change in SOC stocks of -10.7% and -5.2% in the 0-30 cm and 0-100 cm soil layers, respectively. These results are consistent with recent meta-analyses. Don et al (2011), in its meta-analysis of tropical land use change studies, estimated an average relative change of -25.2% for forest converted to cropland, -12.1% for conversion to grassland and -8.6% for conversion to

secondary forest. More recently, Powers et al (2011) estimated changes at -15.4% in average. The rotation cycle and management strategies in this region of Madagascar depend strongly on the requirements of smallholders but are generally 3 years of rainfed rice, 4 to 6 years of fallow followed by either rice or cassava, and so on. These plots tend to turn to grassland after 10 to 15 years. The overall trend observed in this study is, therefore, consistent, but slightly lower, than that in the literature, but provides additional spatially explicit information.

This study gave no significant change in SOC stocks for deforestation in the dry region. There are only a few studies for this climate in the literature. Guo and Gifford (2002) carried out a meta-analysis of 18 studies for regions with less than 1000 mm precipitation per year and found that there was a slight reduction in SOC stocks which was significantly different from zero at 95% confidence. Some studies for higher annual precipitation reported an increase in SOC stocks, although it is not clear what could explain such results.

The detailed analysis of SOC change for different periods of deforestation (1990 to 2000, 2000 to 2005 and 2005 to 2010) showed only very low differences. This suggests that the reduction in stocks occurred the first five years after slash and burn practices. Furthermore, the average potential reduction for areas deforested in 1990-2000 (9.6%) was close to the average of all three periods (10.7%), which showed that the recovery of the SOC stocks is low even after 10 years. This is in agreement with Fujisaki et al (2015) who reported a reduction of 8.5% over 9 years in French Guyana, Brazil, Colombia and Surinam. The slightly higher estimate in this study may be explained by the relatively higher slopes in the study area. The SOC stocks stabilisation or slight recovery after 10 years, may be explained by the crop rotation described above, especially as the land reverts to grassland when it is completely abandoned. Grasslands are known to sequester more carbon in soils than forests (Powers et al, 2012; Fujisaki et al, 2015).

The change in SOC stocks varied considerably, including an increase after deforestation. This has been previously reported (Don et al, 2011) with changes in SOC stocks after deforestation ranging from -80% to +68%. The spatially explicit map of changes in SOC stocks provides a more detailed explanation, in particular concerning the possible role of erosion. There is much discussion about the lateral movement of eroded organic C and its fate within the landscape in agricultural systems: SOC erosion may be a major C source or C sink as SOC translocated by erosion may be buried and protected in hollows or oxidized and emitted (Quiton et al, 2010 in Croft and al, 2012). Locally, SOC stocks after deforestation increased, mainly in the valleys. This may be due to the burial of organic matter as well as rapid regeneration. This hypothesis seems relevant since Chaplot et al (2005), in a study of hill-slopes in northern Laos, showed that most of the SOC material carried by water erosion (84% of 0.069 kgC.m⁻²) accumulated in valley bottoms in areas with steep slopes. Rapid reduction in SOC stocks after deforestation suggests that natural resource managers and policy makers should implement

soil conservation measures immediately after the soil has been exposed (Labrière et al, 2015), even though the SOC may later be displaced.

2.7 Conclusions

This study has proposed a novel approach for estimating potential changes in SOC stocks over a 20 year period without prior information on the soil properties and quantified the effect of deforestation. This landscape scale approach revealed the high variations of SOC stocks with climate and geological basement rock, and lesser variations with topography and soil-vegetation factors. The effect of deforestation was not significant in the dry region (<1000 mm) and an average reduction in SOC stocks of 10.7% was found for the humid region (>1000 mm) area. The largest changes in SOC stocks were in the 0-30 cm soil layer.

However, the direction and magnitude of the change greatly varied at local scale. As clear-cutting forest may increase or reduce SOC stocks depending on the landscape and land management, spatially explicit information on changes in SOC stocks is required to help authorities or NGOs to target sustainable land management actions. It is clear that the higher potential reductions were in soils with high SOC stocks.

Soil carbon change analysis using satellite image shows great potential for evaluating historical changes in regions that do not have a legacy of soil data or monitoring networks. This technique may, therefore, be used as a preliminary approach for evaluating historical trends validated by in-depth social and soil inventories for individual plots. Once validated, the system can provide a cost-effective approach for i) identifying hot spots of changes in stocks and ii) monitoring changes in SOC stocks with limited field data. Building scenarios for future changes would be the next step in developing a decision-making tool including comprehensive information on the actual level of soil degradation or recovery, and the risks and opportunities of various scenarios.

2.8 Acknowledgements

This study was partly funded by IRD (Institut de Recherche pour le Développement), Association Etc Terra and the Programme Holistique de Conservation des Forêts à Madagascar. The first author was funded by an ANRT PhD scholarship (CIFRE N°2012-1153). The authors thank Tony Tebbi for the English revision.

3 Conclusion de l'étude

En conclusion, nous reprenons les trois problématiques qui ont été présentées en introduction :

- **Quel est la distribution des stocks de carbone du sol et ses déterminants dans la zone sud est de Madagascar ?**

Notre étude montre en premier lieu l'importance des variables climatiques (précipitation et température annuelle) pour expliquer la distribution du carbone organique du sol. Cela se traduit par l'existence d'un gradient de COS est-ouest fort (effet de la précipitation) et d'un gradient d'altitude (effet de la température, la température moyenne annuelle étant fortement corrélée à l'altitude). Nous avons également obtenu une part importante de variance expliquée pour les cartes radiométriques et notamment la carte du Thorium, utilisé comme substitut du matériau parental. En effet, le Thorium, tout comme l'Uranium, est un élément qui, une fois libéré par altération chimique des minéraux constituant la roche, est facilement adsorbé sur la matière organique, les argiles et les oxydes (Fe et Al). Il est donc peu déplacé par les phénomènes d'érosion et lessivage. Les autres variables (sol-végétation et topographie) influencent d'une manière moindre le stock de carbone du sol d'un point de vue général (variance expliquée globale) mais ont leur importance pour caractériser des variations locales (ex. différenciation d'une parcelle de jachère ancienne par rapport à une culture).

- **Peut-on détecter des changements significatifs de stocks de carbone de sol avec des images satellites ?**

En utilisant deux jeux de données satellites acquises à la même période de l'année (saison sèche) et à vingt ans d'intervalle, il a été possible de cartographier des changements de stocks de carbone. Pour qu'ils soient « significatifs » nous avons appliqué une série d'étapes de post-traitements afin d'extraire uniquement les pixels ayant subi un changement significatif. La première étape a consisté à enlever les pixels qui étaient « hors gamme » pour les variables sol-végétation (issues du satellite), par rapport à la gamme des valeurs observées sur les points d'inventaire terrain. Ensuite, les ombres liées au relief qui perturbent les réflectances mesurées par le satellite ont été retirées. Enfin, les cartes d'incertitude liées aux estimations de stocks en 1991 et 2011 ont permis d'identifier les changements significativement différents de zéro. Ces étapes ont considérablement réduit le nombre de pixels « utiles », couvrant au final 36% (170 023 ha) de la zone d'étude, à proximité de la zone de référence, et dont 10% (47 287 ha) avaient des changements significativement différents de zéro. Malgré la forte réduction du nombre de pixel lié au post-traitements, cela permet d'obtenir 2 444 242 observations de changement de stocks de carbone entre 1991-2011, ce qui constitue un jeu de données considérable si l'on compare avec les réseaux de mesures de qualité des sol (ex. en

France : 2 200 points relevés tous les 10 ans dans le Réseau de Mesure de la Qualité des Sols - RMQS) ou essai de longue durée (quelques dizaines d'année d'enregistrement sur quelques parcelles).

- **Le cas échéant, quelle est la direction et magnitude de ces variations pour des parcelles de forêt naturelle ayant été converties en champ de culture ?**

Ces observations de changements de stocks de carbone croisées avec les parcelles de déforestation détectées pour la même période indiquent des changements de 10,7 et 5,2% pour les 30 et 100 premiers centimètres de sol respectivement, en région humide. Cela correspond à 8,8 et 7,6 MgC/ha/an de perte en moyenne sur la période 1991-2011. On observe donc une *perte* de carbone après déforestation, mais celle-ci est plus faible que celle traditionnellement rapportée dans les méta-analyses. Aussi, on observe des variations allant de – 27% à 0 % (seuils de quantile de 5 et 95%) ce qui souligne une grande variabilité des changements. Nos résultats ne montrent aucuns changements significatifs en région sèche et des valeurs moyennes faibles (-0,1% et – 0,3% pour 30 et 100 cm de sol). L'amplitude des variations est également faible, de -6,3% (-3,5 MgC/ha/an) à +5,3 (+2,1 MgC/ha/an), laissant envisager autant un déstockage qu'un stockage de carbone après déforestation. Dans cette étude, le nombre d'observations de changement était beaucoup plus faible en région sèche qu'en région humide ce qui constitue une limite à l'interprétation de ces résultats en zone sèche. Cependant, ces sols sont déjà à des niveaux assez faibles de stockage de carbone (38 MgC/ha) ce qui réduit le potentiel de pertes de carbone du sol. Aussi, les capacités de régénération de la végétation sont faibles sous ces climats, ce qui peut expliquer ces faibles gains de stocks de carbone organique du sol observés.

Enfin, notre étude « spatialement explicite » permet de localiser ces zones de perte et leur gradient dans le paysage. On observe par exemple, des pertes plus élevées sur les parties supérieures du versant, comparé au milieu et bas du versant. Des zones de gains (stockage de carbone) sont observées de manière préférentielle en bas de pente et dans les plaines. Ces observations soulignent le rôle de l'érosion sur le stockage du carbone et l'intérêt de réaliser des recherches plus approfondies sur les processus d'érosion et liens avec le stockage et déstockage de carbone du sol.

4 References du chapitre 3

- Adhikari K, Hartemink AE, Minasny B, Bou Kheir R, Greve MB, Greve, M.H (2014) Digital Mapping of Soil Organic Carbon Contents and Stocks in Denmark. PLoS ONE, 9, 8.e105519. doi:10.1371/journal.pone.0105519
- Asner G, Mascaro J, Muller-Landau H, Vieilledent G, Vaudry R, Rasamoelina M, Hall J, van Breugel M (2012) A universal airborne LiDAR approach for tropical forest carbon mapping. *Oecologia*, 168, 4, 1147–1160
- ASTER GDEM. 2011. Global Digital Elevation Model v2. NASA/METI. <http://www.jspacesystems.or.jp/ersdac/GDEM/E/1.html>
- Baccini A, Goetz SJ, Walker WS, Laporte NT, Sun M, Sulla-Menashe D, Hackler J, Beck PSA, Dubayah R, Friedl MA (2012) Estimated carbon dioxide emissions from tropical deforestation improved by carbon-density maps. *Nature Clim Change*, 2, 182–185
- Boenttinger JL, Howell DW, Moore AC, Hartemink AE, Kienast-Brown S (2010) Digital Soil Mapping, Bridging Research, Environmental Application, and Operation. *Progress in Soil Science*, Springer, 439p.
- Breiman L (2001) Random forests. *Machine Learning* 45, 5–32
- Casey RM, Hill T, Woollen E, Ghee C, Mitchard E, Cassels G, Grace J, Woodhouse IH, Williams M (2012) Quantifying small-scale deforestation and forest degradation in African woodlands using radara imagery. *Global Change Biology*, 18, 243-257.
- Chaplot VAM, Rumpel C, Valentin C (2005) Water erosion impact on soil and carbon redistributions within uplands of Mekong River. *Global Biogeochemical Cycles*, 219, 4, doi:10.1029/2005GB002493
- Costa Junior C, Corbeels M, Bernoux M, et al. (2013) Assessing soil carbon storage rates under no-tillage: comparing the synchronic and diachronic approaches. *Soil Tillage Research*, 134, 207-212. <http://dx.doi.org/10.1016/j.still.2013.08.010>
- Cowie AL, Penman TD, Gorissen L et al. (2011) Towards sustainable land Management in the drylands: Scientific connections in monitoring and assessing dryland degradation, climate change and biodiversity. *Land Degradation and Development*, 22, 2448-260

- Croft H, Kuhn NJ, Anderson K (2012) On the use of remote sensing techniques for monitoring spatio-temporal soil organic carbon dynamics in agricultural systems. *Catena*, 94, 64–74
- Don A, Schumacher J, Freibauer A (2011) Impact of tropical land-use change on soil organic carbon stocks – a meta-analysis. *Global Change Biology*, 17, 1658–1670.
- Easter M, Paustian K, Killian K, et al. (2007) The GEFSOC soil carbon modelling system: a tool for conducting regional-scale soil carbon inventories and assessing the impacts of land use change on soil carbon. *Agriculture Ecosystems and Environment*, 122, 1, 13-25. <http://dx.doi.org/10.1016/j.agee.2007.01.004>
- El Hajj M, Bégué A, Lafrance B, Hagolle O, Dedieu G, Rumeau M (2008) Relative Radiometric Normalization and Atmospheric Correction of a SPOT 5 Time Series. *Sensors*, 8, 4, 2774-2791. doi:10.3390/s8042774
- Fujisaki K, Perrin AS, Desjardins T, Bernoux M, Balbino LC, Brossard M (2015) From forest to cropland and pasture systems: a critical review of soil organic carbon stocks changes in Amazonia. *Global Change Biology*. In press. doi:10.1111/gcb.12906
- Goidts E, Van Wesemael B, Crucifix M (2009) Magnitude and sources of uncertainties in soil organic carbon (SOC) stock assessments at various scales. *Eur. J. Soil Sci*, 60, 723–739.
- Goodman SM, Benstead JP (2005) Updated estimates of biotic diversity and endemism for Madagascar. *Oryx*, 39, 73–77.
- Grimm R, Behrens T, Marker M, Elsenbeer H (2008) Soil organic carbon concentration and stocks on Barro Colorado Island-Digital Soil Mapping using Random Forest analysis. *Geoderma*, 146, 102-113.
- Grinand C, Rajaonarivo A, Bernoux M, Pajot V, Brossard M, Razafimbelo T, Albrecht A, Le Martret H (2009) Estimation des stocks de carbone dans les sols de Madagascar. *Étude et Gestion des Sols*, 16, 1, 23-33.
- Grinand C, Barthès BG, Brun D, Kouakoua E, Arrouays D, Jolivet C, Caria G, Bernoux M (2012) Prediction of soil organic and inorganic carbon contents at a national scale (France) using mid-infrared reflectance spectroscopy (MIRS). *European Journal of Soil Science*, 63, 141–151. doi: 10.1111/j.1365-2389.2012.01429.x
- Grinand C, Rakotomalala F, Gond V, Vaudry R, Bernoux M, Vieilledent G (2013) Estimating deforestation in tropical humid and dry forests in Madagascar from 2000 to 2010

- using multi-date Landsat satellite images and the random forests classifier. *Remote Sensing of Environment* 139, 68–80.
- Grunwald (2009) Multi-criteria characterization of recent digital soil mapping and modeling approaches, *Geoderma*, 151, 195-207.
- Guo LB, Gifford RM (2002) Soil carbon stocks and land use change: a meta analysis. *Global Change Biology*, 8, 345–360.
- Gutman, G., Byrnes, R., Covington, M.S., Justice, C., Franks, S., & Headley, R. (2005). Towards Monitoring Land-Cover and Land-Use Changes at a Global Scale: The Global Land Use Survey. *Photogrammetric Engineering and Remote Sensing*, 64, 6-10.
- Hamdi S, Moyano F, Sall S, Bernoux M, Chevalier T (2013) Synthesis analysis of the temperature sensitivity of soil respiration from laboratory studies in relation to incubation methods and soil conditions. *Soil Biology & Biochemistry*, 58, 115-126.
- Harper G, Steininger MK, Tucker CJ, Juhn D, Hawkins F (2007) Fifty years of deforestation and forest fragmentation in Madagascar. *Environmental Conservation*, 34, 1–9.
- Hervieu J (1960). Notice de la carte pédologique de reconnaissance au 1/200 000ème, Fort-Dauphin, feuille N°65. IRSM, 51p.
- Hijmans RJ, Cameron JL, Parra PG, Jarvis A (2005) Very high resolution interpolated climate surfaces for global land areas. *International Journal of Climatology*, 25, 1965-1978.
- Hijmans RJ, Etten JV, Mattiuzzi M, Sumner M, Greeberg JA, Perpinan Lamigueiro O, Bevan, A, Racine EB, Shortridge, A (2015) Reading, writing, manipulating, analyzing and modeling of gridded spatial data. version: 2.3-40, date: 2015-4-10
- IEFN (1997) Carte d'Inventaire Ecologique et Floristique National, République de Madagascar, Madagascar.
- IPCC (2006) IPCC guidelines for national greenhouse gas inventories. Japan: IGES www.ipcc-nggip.iges.or.jp/public/2006gl/index.html.
- Labrière N, Locatelli B, Laumonier Y, Freycon V, Bernoux (2015) Soil erosion in the humid tropics: A systematic quantitative review. *Agriculture, Ecosystems and Environment*, 203, 127–139.
- Lagacherie P, Robbez-Masson JM, Nguyen-The N, Barthes JP (2001) Mapping of reference area representativity using a mathematical soilscape distance. *Geoderma*, 101, 105–

- 118Lal R (2008) The urgency of conserving soil and water to address 21st century issues including global warming. *Journal of Soil and Water Conservation*, 63, 140-141
- Le Maire, G, Marsden C, Nouvellon Y, Grinand C, Hakamada JS, Laclau JP (2011a) MODIS NDVI time-series allow the monitoring of Eucalyptus plantation biomass. *Remote Sensing of Environment*, 115, 10, 2624-2625
- Le Maire G, Marsden C, Verhoef W, Ponzoni FJ, Lo Seen D, Bégué A, Stape JL, Nouvellon Y (2011b) Leaf area index estimation with MODIS reflectance time series and model inversion during full rotations of Eucalyptus plantations. *Remote Sensing of Environment*, 115, 586–599.
- Liaw A, Wiener M (2014) Breiman and Cutler's random forests for classification and regression: Classification and regression based on a forest of trees using random inputs. version: 4.6-10. date: 2014-07-17
- Lo Seen D, Ramesh BR, Nair KM, Martin M, Arrouays D, Bourgeon G (2010) Soil carbon stocks, deforestation and landcover changes in the Western Ghats biodiversity hotspot (India). *Global Change Biology*, 16, 1777-1792.
- Malone BP, McBratney AB, Minasny B, Laslett, GM (2009) Mapping continuous depth functions of soil carbon storage and available water capacity. *Geoderma* 154, 138–152.
- McBratney AB, Mendonça ML, Minasny B (2003) On digital Soil Mapping. *Geoderma* 117, 3–52.
- McCarty G, Reeves J, Reeves V, Follett R, Kimble J (2002) Mid-infrared and near-infrared diffuse reflectance spectroscopy for soil carbon measurement. *Soil Science Society of America Journal*, 66, 640–646.
- MEFT, Ministry of the Environment, Forest and Tourism of Madagascar (2009) Evolution de la couverture de forêts naturelles à Madagascar, 1990–2000–2005. Antananarivo, Madagascar, pp 132.
- Milne E, Al-Adamat R, Batjes NH, et al. (2007) National and sub national assessments of soil organic carbon stocks and changes: the GEFSOC modelling system. *Agriculture Ecosystems and Environment*, 122, 1, 3-12.
<http://dx.doi.org/10.1016/j.agee.2007.01.002>

- Milne E, Banwart SA, Noelle-meyer E et al. (2014) Soil carbon, multiple Benefits. Environmental Development. <http://dx.doi.org/10.1016/j.envdev.2014.11.005>
- Minasny B, McBratney AB, Murray Lark R (2008) Digital soil mapping technologies for countries with sparse Data Infrastructures. Chapter 2 in Digital Soil Mapping with Limited Data, Hartemink et al, pp. 15-30
- Minasny B, McBratney AB, Malone BP, Wheeler I (2013) Digital Soil Mapping of Soil Carbon. Advances in Agronomy, 118. doi.org/10.1016/B978-0-12-405942-9.00001-3
- Morvan X, Saby NPA, Arrouays D, et al. (2008) Soil monitoring in Europe: a review of existing systems and requirements for harmonisation. Science of the Total Environment, 391, 1–12.
- Mulder VL, de Bruin S, Schaepman ME, Mayr TR (2011) The use of remote sensing in soil and terrain mapping — A review. Geoderma, 162, 1–19
- Phachomphon K, Dlamini P, Chaplot V (2010) Estimating carbon stocks at a regional level using soil information and easily accessible auxiliary variables. Geoderma, 155, 372–380.
- Post WM, Izaurraalde RC, Mann LK, Bliss N (2001) Monitoring and Verifying changes of organic carbon in soil. Climatic Change, 51, 73-99.
- Powers JS, Corre MD, Twine TE, Veldkamp E (2011) Geographic bias of field bservations of soil carbon stocks with tropical land-use changes precludes spatial extrapolation. PNAS. 108, 15, 6318–6322
- R Development Core Team., 2005. R: A language and environment for statistical computing, R Foundation for Statistical Computing, Vienna, Austria. ISBN 3-900051-07-0, URL <http://www.R-project.org>.
- Rodriguez-Galiano VF, Ghimire B, Rogan J, Chica-Oimo M, Rigol-Sanchez J P (2012) An assessment of the effectiveness of a random forest classifier for land-cover classification. ISPRS Journal of Photogrammetry and Remote Sensing, 67, 93–104
- Rabenarivo M., Chapuis-Lardy L., Brunet D., Chotte J.L., Rabeharisoa L., Barthès BG (2013) Comparing near and mid-infrared reflectance spectroscopy for determining properties of Malagasy soils, using global or LOCAL calibration. Journal of Near Infrared Spectroscopy, 21, 495-509.

- Rawlins BG, Marchant BP, Smyth D, Scheib C, Lark RM, Jordan C (2009) Airborne radiometric survey data and a DTM as covariates for regional scale mapping of soil organic carbon across Northern Ireland. *Eur. J. Soil Sci.* 60, 44–54.
- Razafimbelo T, Albrecht A, Feller C (2010) Stockage de carbone dans les sols sous systèmes de culture en semis direct sous couvert végétal (SCV) dans différents contextes pédoclimatiques à Madagascar. *Etude et Gestion des sols*, 17, 139-154
- Razakamanarivo RH, Grinand C, Razafindrakoto MA, Bernoux M, Albrecht A (2011) Mapping organic carbon stocks in eucalyptus plantations of the central highlands of Madagascar: a multiple regression approach. *Geoderma* 162, 335–346.
- Vagen TG, Andrianorofanomezana MAA, Andrianorofanomezana S (2006) Deforestation and cultivation effects on characteristics of oxisols in the highlands of Madagascar. *Geoderma* 131, 190 – 200.
- Vagen TG, Winowiecki LA (2013) Mapping of soil organic carbon stocks for spatially explicit assessments of climate change mitigation potential. *Environ. Res. Lett.* 8. 1-9, doi:10.1088/1748-9326/8/1/015011
- Vieilledent G, Grinand C, Vaudry R (2013) Forecasting deforestation and carbon emissions in tropical developing countries facing demographic expansion: a case study in Madagascar. *Ecology and Evolution*, 3, 6, 1702–1716. doi: 10.1002/ece3.550
- Vieilledent G., O. Gardi, C. Grinand, C. Burren, M. Andriamanjato, C. Camara, C. J. Gardner, L. Glass, A. Rasolohery, H. Rakoto Ratsimba, V. Gond, Rakotoarijaona J.R. (2016) Bioclimatic envelope models predict a decrease in tropical forest carbon stocks with climate change in Madagascar. *Journal of Ecology*. 104, 703-715.
- Viscarra Rossel RA, Walvoort DJJ, McBratney AB, Janick LJ, Skjemstad JO (2006) Visible, near infrared, mid infrared or combined diffuse reflectance spectroscopy for simultaneous assessment of various soil properties. *Geoderma*, 131, 59-75.
- Screenivas K, Sujatha G, Sudhir K, Vamsi Kiran D, Fyze MA, Ravisankar T, Dadhwal VK (2014) Spatial Assessment of Soil Organic Carbon Density Through Random Forests Based Imputation. *Journal of Indian Society of Remote Sensing*. doi:10.1007/s12524-013-0332-x
- Shepherd KD, Walsh MG (2002) Development of reflectance spectral libraries for characterization of soil properties. *Soil Science Society of America Journal*, 66, 3, 988–998.

- Smith P, Davies CA, Ogle S, et al. (2012) Towards an integrated global framework to assess the impacts of land use and management change on soil carbon: current capability and future vision. *Global Change Biology*, 18, 2089–2101, doi: 10.1111/j.1365-2486.2012.02689.x
- Wiesmeier M, Barthold F, Blank B, Kögel-Knabner I (2011) Digital mapping of soil organic matter stocks using Random Forest modeling in a semi-arid steppe ecosystem. *Plant Soil*. 340, 7–24. doi:10.1007/s11104-010-0425-z
- Wilford J, Minty B (2006) The use of airborne gamma-ray imagery for mapping soils and understanding landscape processes. Chapter 16 in *Digital Soil Mapping - An Introductory Perspective*, Hartemink A.E., McBratney, A., volume 31, pp 207-218, 609-610

Chapitre 4 - Modélisation des changements d'usage des terres

1	CONTEXTE DE L'ÉTUDE	124
1.1	CHALLENGES.....	124
1.2	INNOVATIONS	125
1.3	PROBLÉMATIQUES SCIENTIFIQUES	126
2	DEFORESTATION, LAND DEGRADATION AND REGENERATION MODELING USING MACHINE LEARNING TOOLS AND GLOBAL CHANGE DATASET: ASSESSMENT OF THE DRIVERS AND SCENARIOS OF LAND CHANGE IN MADAGASCAR	127
2.1	RÉSUMÉ	128
2.2	ABSTRACT	129
2.3	INTRODUCTION	130
2.3.1	<i>International context: targeting the drivers of change.....</i>	<i>130</i>
2.3.2	<i>Drivers of change analysis: no common framework.....</i>	<i>130</i>
2.3.3	<i>Land change modeling: limitations and the way forward</i>	<i>131</i>
2.3.4	<i>Madagascar: a need for regional sound and comprehensive information</i>	<i>131</i>
2.3.5	<i>Objectives.....</i>	<i>132</i>
2.4	MATERIAL AND METHODS	133
2.4.1	<i>Study site.....</i>	<i>133</i>
2.4.2	<i>Land use transitions dataset.....</i>	<i>134</i>
2.4.3	<i>Potential land change predictors</i>	<i>134</i>
2.4.4	<i>Importance of drivers.....</i>	<i>135</i>
2.4.5	<i>Model construction</i>	<i>135</i>
2.4.6	<i>Model assessment.....</i>	<i>136</i>
2.4.7	<i>Predicting future transitions areas.....</i>	<i>137</i>
2.5	RESULTS & DISCUSSION	138
2.5.1	<i>Observed historical changes</i>	<i>138</i>
2.5.2	<i>What are the drivers of deforestation, degradation and regeneration?</i>	<i>139</i>
2.5.3	<i>Land change model accuracies</i>	<i>143</i>
2.5.4	<i>Where is change likely to occur in 2034?.....</i>	<i>144</i>
2.5.5	<i>Conservation threats and development opportunities.....</i>	<i>147</i>
2.5.6	<i>Lessons learned and recommendations for REDD+ baseline development.....</i>	<i>148</i>
2.6	CONCLUSION	149
2.7	AKNOWLEDGMENTS.....	150
3	CONCLUSION DE L'ÉTUDE	151
4	REFERENCES DU CHAPITRE 4	153

« There is an urgent need for the carbon cycle policy and management communities to move beyond the simple human emissions-atmospheric CO₂ equation and to take a much more holistic view of the carbon cycle – its natural dynamics, feedbacks, nonlinearities and potential surprises »

(Steffen, 2006)

“All models are wrong, but some are useful”

(George Box, quoted in Kennedy 1992)

1 Contexte de l’étude

1.1 Challenges

Afin d’établir des scénarios de référence REDD+ (voir chapitre 1, section 1.3) et plus largement pour construire des scénarios utiles aux décideurs, il est nécessaire d’évaluer l’influence des facteurs biophysiques et socio-économiques expliquant la déforestation. À l’échelle globale, les évaluations des facteurs de la déforestation réalisées depuis plus d’une dizaine d’années ne fournissent pas de messages clairs, les facteurs pouvant agir à la fois positivement et négativement sur la déforestation (Geist and Lambin, 2001 ; Ferretti-Gallon and Bush, 2014). Ce fait à lui seul pourrait expliquer pourquoi les politiques REDD+ ont des difficultés à démontrer leur efficacité (Weatherley-Singha et Gupta, 2015). Contrairement au suivi de la déforestation et à l’estimation des stocks de carbone dans les arbres et le sol, il n’existe pas aujourd’hui de cadre méthodologique accepté par la communauté scientifique pour la modélisation des changements d’usage des terres. Les modèles actuels échouent à capturer la complexité des processus en jeu (Velddkamp and Lambin, 2001). La disponibilité des données (quantité et données) et les outils statistiques utilisés influencent grandement les résultats.

À Madagascar, deux études nationales ont montré que la population rurale et la pauvreté n’étaient pas les premiers facteurs responsables de la déforestation d’un point de vue statistique, contrairement au discours dominant sur les causes de la déforestation à Madagascar (Gorenflo et al, 2010 ; Thomas 2007). Il existerait des interactions plus complexes entre l’homme et son environnement, à l’échelle régionale, voire locale. Ces études se sont intéressées uniquement à l’importance des facteurs (corrélation par régression multivariée) et concernant la déforestation enregistrée entre 1990 et 2000. Une étude plus récente, à l’échelle régionale, s’est appuyée sur des données de déforestation de la dernière décennie (2000-2010) et a étendu l’analyse statistique des auteurs précédents en proposant une méthode intégrant la projection spatiale de la déforestation (Vieilledent et al, 2013). Les projections spatialisées ont l’avantage de i) permettre une validation des résultats – par comparaison des cartes de changement projetés et avec les cartes de changements observés – et ii) proposer des scénarios d’émissions de CO₂ de niveau 3 d’incertitude en croisant les cartes de déforestation future avec des cartes de stocks de carbone de la biomasse et du sol. Une des limites de cette dernière étude est qu’elle ne considère pas les changements d’usage hors des zones de forêt intacte. Or, le mécanisme REDD+, ainsi que d’autres politiques de gestion des terres, demandent d’élaborer des scénarios prenant en compte tous les changements d’usage des terres ayant un impact sur carbone contenu dans les écosystèmes terrestres. C’est le cas de la dégradation des terres et de la régénération qui sont par ailleurs

des processus clés de gains ou pertes de services écosystémiques (production végétale, rétention en eau, contrôle de l’érosion).

Afin de fournir des conseils de gestion des terres, nous avons besoins d’évaluer ces trois processus, de façon spatialisés, à des résolutions compatibles avec de la gestion « opérationnelle » et sur de grands territoires. Les satellites fournissent des informations biophysiques objectives, exhaustives sur le territoire et répétées dans le temps qu’il est aujourd’hui possible de traiter à l’échelle mondiale sur plus d’une vingtaine d’années. C’est le cas avec les données de Hansen et al (2013). Les auteurs détectent automatiquement des variations de couverture de végétation chlorophyllienne sur la période 2000-2014, que ce soit des pertes ou des gains, et à une résolution de 30 mètres. Ces données couplées avec des connaissances locales permettraient d’étudier les trois dynamiques simultanément, n’importe où dans le monde. Ceci n’a pas encore été testé à notre connaissance.

La complexité des relations entre les processus étudiés (déforestation, dégradation, régénération) et les facteurs potentiels (paysagers, lié aux infrastructures, socio-économique) questionne également notre capacité à analyser ces données. Les études de modélisation de la déforestation utilisent principalement des méthodes de régression linéaires multivariées. Cependant la nature des relations n’est pas linéaire et est dépendante de l’échelle d’analyse (facteurs influençant à l’échelle locale, régionale ou nationale) (Velddkamp and Lambin, 2001). Les outils d’apprentissage automatique (*machine learning*), utilisés pour la fouille de données (*data mining*), apportent des solutions techniques pour gérer des problèmes complexes, avec des conditionnalités et des relations non linéaires. Ils permettraient *a priori* l’élaboration de modèles prédictifs plus robustes. C’est le cas notamment de l’algorithme Random Forest qui est utilisé dans de nombreux domaines dont la finance, l’épidémiologie et la télédétection mais n’a pas été testé dans des applications de modélisation des changements d’usages des terres.

1.2 Innovations

Dans cette étude nous proposons plusieurs innovations :

- Évaluation simultanée des processus de déforestation, de dégradation et de régénération à partir de données facilement accessibles sur la période 2000-2014.
- Analyse de l’importance des facteurs biophysiques et socioéconomiques expliquant ces trois processus à partir d’une méthode empirique et d’une méthode de régression linéaire.
- Test des nouveaux algorithmes pour la prédiction des changements d’usage des terres.

- Élaboration et projection de scénarios pour analyser les menaces et opportunités liées à la gestion des aires protégées et non protégées.
- Développement d’une méthodologie « *open source* » et en ligne de commande pour la transparence et la reproductibilité de l’étude.

1.3 Problématiques scientifiques

A travers cette étude, on cherche à répondre à ces trois questions :

- Quels sont les facteurs biophysiques et socioéconomiques responsables de la déforestation, de la dégradation des terres et de la régénération?
- Est-ce que les outils d’apprentissage automatiques (*machine learning*) permettent d’obtenir de meilleures prédictions comparés aux outils traditionnels de régression linéaire ?
- Quelles sont les menaces et opportunités de changements d’usage des terres dans et en dehors des aires protégées selon différents scénarios de changements d’usage des terres ?

2 Deforestation, land degradation and regeneration modeling using machine learning tools and global change dataset: Assessment of the drivers and scenarios of land change in Madagascar

Article submitted to Landscape Ecology in September 2016

Grinand C.^{1,2}, Vielledent G.^{3,4}, Razafimbelo T.⁵, Rakotoarijaona JR.⁶, Bernoux, M.^{2,7}

¹ ETC Terra, 127 rue d'Avron, 75020, Paris, France

² IRD, Eco&Sols, 2 Place Viala, F-34060 Montpellier, France

³ Cirad, UPR BSEF, F-34398 Montpellier, France

⁴ Joint Research Center of the European Commission, Institute for Environment and Sustainability, I-21027 Ispra, ITALY

⁵ Laboratoire des Radio-Isotopes, Route d'Andraisoro, 101 Antananarivo, Madagascar

⁶ Office National pour l'Environnement, Ave Rainilaiarivony, Antaninarenina BP 822 Lalana Ratsimilaho, Antananarivo, Madagascar

⁷ FAO, Food and Agriculture Organization of the United Nations,

* Contact author: c.grinand@etcterra.org

2.1 Résumé

La déforestation, la dégradation des terres, et la régénération des terres sont des processus rapides et complexes qui impactent grandement le climat, la fourniture de services écosystémiques et le bien-être des populations. Une réponse appropriée à travers la planification des usages des terres doit être appuyée par une analyse compréhensive des facteurs et des informations spatialisées sur les risques et opportunités. Dans cette étude, nous explorons l’utilisation de données très haute résolution de changement de la couverture végétale et des données socio-économiques afin de cartographier le potentiel de déforestation, la dégradation des terres et la régénération. Ces cartes de potentiel ont été utilisées pour élaborer trois scénarios de changements d’usage des terres pour les deux prochaines décades (2015-2034) en considérant les tendances passées et des données connaissances locales. Enfin, nous avons évalué ces résultats au regard de la présence d’aires protégées ou non.

L’observation historique entre 2001 et 2014 a montré des tendances claires de fortes déforestation (1774 ha.an⁻¹), forte dégradation des terres (2737 ha.an⁻¹) and faible régénération (302 ha.an⁻¹) sur une zone d’étude de 1,600,000 ha. Parmi les douze facteurs potentiels, la distance à la forêt et l’altitude furent les plus déterminants pour les trois transitions. La pente, l’orientation de la pente et la distance aux villages influencent aussi les changements d’usage mais dans une moindre mesure. La validation des modèles de changement a montré des résultats satisfaisants avec des valeurs de AUC-ROC au-dessus de 0.8 et des précisions globales supérieurs à 75%. Les scénarios « business-as-usual » montrent de grandes surfaces sous la menace d’être défrichées ou dégradées le long de la lisière forestière et à l’intérieur d’un des deux Parc National (Parc National de Midongy). De manière surprenante, les zones « non-forestées » présentent dans ce même Parc de fortes semble offrir des opportunités de régénération.

Cette méthode a permis de fournir une évaluation compréhensive des facteurs de changement d’usage des terres. L’outil est adaptatif et peut être facilement répliqué ou mis à jour avec des données plus précises ou actualisées. Nous pensons que la méthode peut être utilisée dans les pays en voie de développement afin de répondre aux exigences REDD+ (niveau d’émission de référence), cibler des interventions au sol (gestion des aires protégées) ou développer un stratégie de gestion durable des terres.

Mots clés REDD+, facteurs, Madagascar, Random Forest, changement d’usage des terres, modélisation spatiale

2.2 Abstract

Deforestation, land degradation and land regeneration are rapid and complex processes that greatly impact climate regulation, ecosystem services provision and population well-being. Appropriate response through land use planning and intervention should be enlightened by a comprehensive driver's analysis and risk and opportunity spatially-explicit information. In this study we explore the use of high resolution global vegetation change, biophysical and socio-economic datasets to map deforestation, land degradation and regeneration suitability. These potential change maps were used to draw three scenarios of change for the two next decades (2015-2035) considering past trends intensity of change and expert knowledge. We finally assessed these outputs based on existing protected and non-protected areas.

Historical observation during 2001-2014 displayed clear patterns of high deforestation (1774 ha.y^{-1}), high degradation (2737 ha.y^{-1}) and low regeneration (302 ha.ha^{-1}) over the 1,600,000 ha study area. Amongst the twelve potentials predictors, distance to natural habitat and elevation were the most important for the three land transitions. Slope, aspect, and distance to villages also influence land change to a lesser extent. Validation of land change models showed satisfactory figures with ROC values above 0.8 and overall accuracy above 75%. Business-as-usual scenarios highlighted the large areas under deforestation and degradation threat along the eastern forest edge of the study area and within one of the two National Parks. Surprisingly, the neighboring and non-forested areas of this latter park showed the highest opportunity for land regeneration.

The approach was successful to provide a comprehensive assessment of drivers of land use change. The tool is adaptive, easy to replicate as better or updated dataset are made available. Thus we believe it could be used in developing countries to meet their REDD+ requirements (reference emissions levels), to target their local interventions (control in protected areas) or develop large scale sustainable land management strategies.

Keywords: REDD+, driving forces, Madagascar, Random Forest, land use change, spatial modeling

2.3 Introduction

2.3.1 International context: targeting the drivers of change

Agriculture, Forestry and Other Land Use (AFOLU) sector which is responsible for a quarter of the global anthropogenic greenhouse gas (GHG; IPCC, 2014) emissions is under scrutiny for finding pathways to mitigate climate change and improve population livelihood through sustainable land management. Mitigation mechanisms under the scope of the environmental United Nations conventions, such as Reduction of Emissions due to Deforestation and Forest Degradation (REDD+) under the United Nation Convention of Climate Change (UNFCCC) or Land Degradation Neutrality under the United National to Combat Degradation and Desertification (UNCCD) requires to identify drivers of land allocation change in order to i) quantify the impact on ecosystem good and services and ii) design appropriate strategies. However, a growing number of scientific assessments of the drivers of deforestation are reaching diverging conclusions (Ferretti-Gallon and Bush, 2014) and may explained why current REDD+ policies are struggling to demonstrate their effectiveness as a benefit-sharing solution (Weatherley-Singha et Gupta, 2015).

2.3.2 Drivers of change analysis: no common framework

Assessing the driving forces behind land cover change is key for understanding changes in our global environment (Bax et al, 2016) and to build realistic models of land use change (Veldkamp et Lambin, 2001). However, they are difficult to quantify and assess since they have long underlying causal chains – also referred to biophysical feedback (Verburg, 2006) or socio-economical retroactions - and take different shapes depending on the perspective that is chosen (Wehkamp et al, 2015). For instance, often used perspective described by Geist and Lambin (2001) distinguish direct drivers (or proximal) and indirect (or underlying causes) drivers. The former is defined as human activities or actions at the local level which directly lead to the conversion of land into another land use such as forest clearing due to agricultural expansion or mining. The latter implies complex social processes at various scales which “underpin or sustain the direct drivers” such as the demographic expansion or the price of commodities. They are then analyzed either from a process-driven or data-driven modeling framework. Nonetheless, all the models fail to capture all the complexity (Veldkamp and Lambin, 2001). There is now no current accepted framework to assess the driving forces of land change process as the availability of the input dataset (quantity and quality) and assumptions used (correlation or causality) greatly influence the results.

2.3.3 Land change modeling: limitations and the way forward

Spatially-explicit land change model have the net advantage to assess the drivers and predict the potential land change location in transparent and verifiable manner. It has been reported that the three most important criteria for policy makers are compliance with IPCC Good Practice Guidelines, clarity and dynamic baseline updating (Huettnner et al, 2009). In fact, three out of four REDD+ methodologies under the Voluntary Carbon Standard (VCS) require to project the location of the future deforestation regarding the baseline scenario (Shoch et al, 2013). As mentioned above, those methodologies heavily rely on input dataset and model assumptions. The former is usually land cover change maps with a certain level of accuracy due to operator bias and satellite images classification techniques. Models are highly diverse, and can be separated in two families, either linear or non-linear. Veldkamp and Lambin(2001) argues that linear model are prone to numerical instability as “small measurement errors in input data can propagate and lead to spurious results, given the intrinsic non-linear behavior of the modelled system”. On the contrary, non-linear algorithms such as decision trees are able to capture non-linear observation-variable relationships but are still scarcely used. To our knowledge decision tree models has not been tested yet in spatially explicit land change model application.

Two decades of high resolution remote sensing images allow to detect land use change in an unprecedented manner. Notably, Hansen et al (2013) published a globally consistent and locally relevant dataset of vegetation cover gain and loss over a 14 years period, until 2014. This dataset provides a mean to assess key ecosystem dynamics such as deforestation, and land degradation and regeneration, assuming that tree cover is a proxy of numerous ecosystem services. In this study we explore this easy to access, globally available vegetation change dataset combined with machine learning algorithms. The overall objective of this research is to provide low bias and adaptive land change modeling framework.

2.3.4 Madagascar: a need for regional sound and comprehensive information

Madagascar is recognized as a major biodiversity reservoir in the world, mainly located within its intact or natural forest. Recent studies highlighted a dramatic increase of deforestation. On a national scale, a study revealed a shift from 0.5% of deforestation (21 710 ha.y-1) for the 2005-2010 period, to 0.92% by year (34 567 ha.y-1) regarding the tropical humid forest (Rakotomalala et al, 2015) and also dramatic figures in the dry and spiny forest area (ONE et al, 2015). These figures are corroborated by other studies (<http://www.globalforestwatch.org/country/MDG>). Today, the total remaining intact forest is less than 8 485 509 ha (ONE et al, 2015) when it used to be 10 605 700 ha in 1990 (Harper et al, 2005) corresponding to 20 % of forest loss in 25 years. Madagascar is involved in REDD+

scheme since 2008 and, with the help of Facility Forest Carbon Partnership (R-PIN Madagascar, 2008), has recently validated its REDD+ Readiness Preparation Proposal describing the national REDD+ strategy (RPP Madagascar, 2014) and proposed an Emission Reduction Program in a rainforest pilot region (ER-PIN, 2015). In those national and subnational scales REDD+ documents, there is a broad knowledge of the deforestation factors and underlying driving forces but they are neither quantified nor represented spatially. Land use change spatial assessment in REDD+ countries such as Madagascar is urgently required i) to estimate the impact of avoided deforestation programs and the effectiveness of conservation efforts and ii) build comprehensive possible future with sound economic and environmental assessment.

2.3.5 Objectives

The first aim of this paper was to develop, test and validate a new tool with high resolution spatially explicit potential change maps of deforestation, degradation and regeneration. Then, we proposed land change scenarios on a regional scale. The approach was tested on the south-east region of Madagascar, a region that displays high level of biodiversity (two national parks) and a high rate of deforestation.

We first compiled a historical change dataset from the global forest change dataset, which recorded gain and loss at 30 m pixel for the 2000-2014 period. Using a benchmark forest cover in 2000, we converted this raw dataset into three land change transitions: deforestation, land degradation and land restoration. We collected and prepared twelve potential land change predictors and statistically assessed their contribution to explain the three land change processes. Validation of the model was performed using several commonly used land change accuracy metrics. Three land change scenarios were built and used to assess the impact of effectiveness of natural protected areas and areas with currently no protected status.

2.4 Material and methods

2.4.1 Study site

The study area is located in the southern part of the tropical humid forest corridor of Madagascar, around 70 km wide east-west axis and 200 km long in the north-south axis (1 676 000 ha). The region is marked by a large east-west gradient of precipitation, from 2000 to 700 mm (Wordclim database, Hijmans et al, 2005). Four great landscapes can be distinguished: the flat sandy coast line, the humid rough terrain montane, the downhill mosaic crop-savannah system and the semi-arid gently sloping west corridor area. Two national parks are located in the study area. One to the south, the Anohahela National Parks which was created at first as a national reserve in 1934 and one to the North, the Midongy National Park, more recently created (1997). They cover 46.8% (191 970 ha) of the forested area of the study area. Biodiversity is mainly located in forested areas (Vieilledent et al, 2016). The soils are dominated with ferralitic soils developed from igneous rock, more or less truncated by erosion processes, leading to local deposit of sand and silt in the valleys. The agricultural system is dominated by irrigated rice cropping systems and swidden agriculture of rained rice, associated with cassava, maize in more or less long crop-fallow rotation. Other activities include cattle ranching and cash crop production, mainly coffee. Population is rural, with only 11 towns holding more than one food market a week (or above 10 000 inhabitants) and 1417 villages (figure 1).

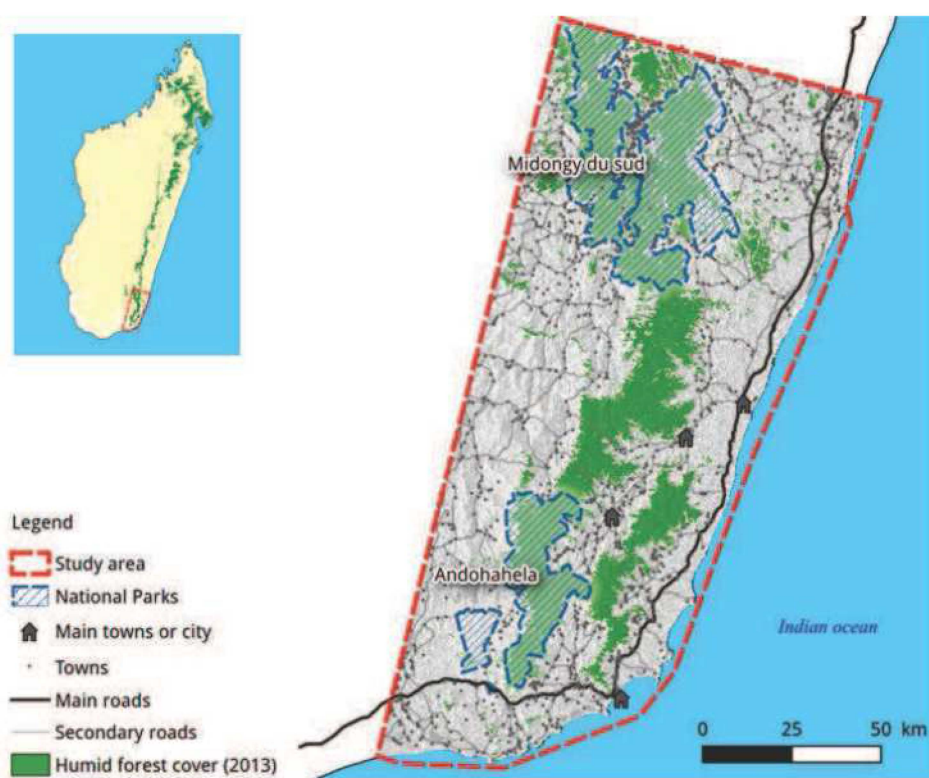


Figure 1: Location of the study area in the south east tropical humid corridor. Sources: SAPM 2010, BD200 FTM, Rakotomalala et al, 2015.

2.4.2 Land use transitions dataset

We used here the land use transition produced by Hansen et al. (2013) for the 2000-2014 period, available globally. These 30 m pixel scale observations were extracted from massive Landsat image time series and represent the trend of gain or loss of forest over the 2000-2014 period (Hansen et al, 2013). In this study, the term “forest” refers to tree cover, and trees were defined as “all vegetation taller than 5 m in height at Landsat pixel scale”. We thus refer to vegetation or tree cover instead of forest in the following paper. As in all remote sensing study, vegetation was characterized by reflectance value in the visible and near infra-red regions, synthetically expressed through the Normalized Difference Vegetation Index (NDVI). NDVI express the active photosynthetic radiation captured by the plant and has been widely used as a proxy of land or biomass productivity (Yengoh et al, 2014). By extension, it can serve as an indicator of land health status, and is often used to assess land degradation as a whole (UNEP, 2012; Bai et al, 2013; Yengoh et al, 2014). In Hansen et al (2013), forest loss was defined as a stand-replacement disturbance or complete removal of tree cover canopy, excluding selective removal of tree that do not lead to non-forest state. Forest gain was defined as the inverse of loss, to say, a non-forest to forest change, excluding stand of tree cover that was non-forest in 2000.

Taking vegetation cover loss and gain from Hansen et al (2013) dataset as a proxy of land degradation and recovery, we applied a threshold of natural forest extent from another study that used intensive photo-interpretation (Grinand et al, 2013) to differentiate vegetation loss pixels within and outside intact forest extent at initial date (2000). Finally, we interpreted loss within intact forest as deforestation, vegetation loss outside intact forest extent as land degradation and vegetation gain as regeneration.

2.4.3 Potential land change predictors

We derived twelve potential predictors of land change that were converted into spatially explicit layers and included in our analysis. Protected areas were categorized in 3 levels, the two national parks and outside, the remaining variables were computed as continuous dataset. They represent three types of predictors usually tested in spatially explicit land change studies (Bax et al, 2016, Aguilar-Amuchastegui et al, 2014, Ferretti-Gallon and Bush, 2014) and already tested in Madagascar (Thomas, 2007, Veilledent et al, 2013). The first type represent predictors related to the amount of time required to access the land and transport goods to

market. We used here the elevation, slope, proximity to towns or villages, proximity to main roads or secondary roads and proximity to the forest edge. The second type represents factors of potential productivity of land under agriculture. We used here proximity to the aspect, proximity to water course and the number of dry months, defined as the number of months with potential evapotranspiration higher than monthly rainfall (www.madaclim.org). Last predictor type expresses land tenure and land regulation. In this study area, we used the two national parks delimitations collected from the SAPM Protected Areas System of Madagascar (“Système des Aires Protégées de Madagascar”), and the population density aggregated at county level (“communes”), from a 2006-2009 census collected by the INSTAT (“Institut National de la Statistique à Madagascar”). The full description of the dataset used and their spatial representation are presented in supplementary materials (Table S1 and Figure S1)

2.4.4 Importance of drivers

Prior to modeling, we carried out an assessment of the drivers of deforestation, land degradation and regeneration processes by intersecting the land change observation and the spatial predictors. We used a stratified random sampling scheme, by sampling 10 000 observations in no change areas and 10 000 observations in the land change category. Observed probabilities (ratio of change observation divided by the total observations) were computed for quantiles on the predictor range values. This allows to have a quick view of the influence of each factor, with values above 0.5 having a positive effect on change, a negative effect with values below 0.5, and a straight line around the 0.5 value meaning no influence. Additionally, to this empirical analysis, we tested the usual linear model approach to assess the direction (positive or negative) and correlation significance of each predictor, and then compared both outputs.

2.4.5 Model construction

Leading LULCC modeling framework such as Land Change Model (Eastman, 2015), Geomod (Pontius et al, 2001) or Dinamica-Ego (Soares-Filho et al., 2009) use statistical models or modeling chains which implies tuning numerous key parameters which may greatly impact the results. In this study we tested one traditional generalized linear model (GLM) as a reference and two machine learning tools. They require low parameterization and are able to deal with complex, conditional and non-linear relationships. The first one is Maxent (Maximum Entropy; ME) is the most widely used species distribution models and having recently been used in a deforestation modeling study (Aguilar-Amuchastegui, 2014). The second is Random Forest (RF; Breiman et al, 2001) which has not been tested yet to our knowledge in land change modeling studies. Random Forest model is being increasingly used in a large variety of application in environment using large spatial co-variables dataset,

including carbon mapping (Baccini et al, 2012, Vielledent et al, 2016), land cover (Gislason et al, 2006) and deforestation monitoring (Grinand et al, 2013). It combines the advantage of bagging (random selection of individual and variable) and simple decision tree (recursive binary split in the explanatory variable dataset) that can be used to solve both regression and classification problems. In this paper, RF was used in the classification mode using two classes and class membership was further processed. The three models were calibrated using the same point dataset presented above (20 000 observations). Once calibrated the model was applied onto the spatial predictor layer stack to predict the probability of the land change category, over the study area at 30 m pixel. We referred to the three transition probability maps as deforestation risk map, land degradation risk map and land regeneration suitability respectively.

2.4.6 Model assessment

Model accuracy assessment is a key step in LULC modeling as it involves providing sound information to stakeholders about potential future land use dynamics. In this study, we randomly sampled 20 000 points within the initial state cover, to say, forest extent in 2000 for deforestation accuracy assessment and non-forest extent in 2000 for land degradation and regeneration accuracy assessment. On those points, we predicted the land transition probabilities by using the above-mentioned calibrated models. We determined the 2014 land allocation by using the observed rate of change on the historical 2000-2014 (tableau 14) period and assigned the highest probability values to “change” value (value of 1), the remaining pixels being assigned as “no change” (value of 0). We then calculated commonly used accuracy metrics: the area under the Receiver Operating Characteristic (ROC, also referred as AUC in the literature), the Figure of Merit (FOM) and user’s accuracy indexes. The ROC is the most commonly used metrics for species distribution model (Elith et al, 2006). This statistic was computed using the pROC package available in R (Robin et al, 2011). It allows to assess the predictive power of the land change model, a value of 1 meaning a perfect predictive power, 0.5 meaning that the model is no better than random, values below 0.5 indicates systematic incorrect prediction (Pontius and Schneider, 2001). We also computed the FOM as it is a required indicator in REDD+ methodologies (Shoch et al, 2013), although this indicator is correlated with the net area of change (Pontius et al, 2008) which underpinned study-to-study comparisons. REDD+ methodologies usually require to have FOM value greater or equal to the net change ratio. The formulas used to derive each accuracy metrics are presented in the table 1 below.

Tableau 14 : *Illustration of the change matrix used for validation and derived accuracy indexes.*

		Reference	
		No change (0)	Change (1)
Predicted	No change (0)	A	D
	Change (1)	C	B

Overall accuracy: $OA = (A+B)/(A+B+C+D)$

User accuracy of change: $UA_c = B / (B+C)$

User Accuracy of no change: $UA_{NC} = A / (A+D)$

Balanced User Accuracy: $UA = (UA_c + UA_{NC})/2$

Figure of Merit: $FOM = B / (B+C+D)$

Where A indicate the correctly predicted (true negative), B is the correctly predicted presence of land change (true positive), C is the no change pixel predicted as change (false positive) and D is the change observations predicted as no change (false negative).

2.4.7 Predicting future transitions areas

There are two types of land model, those who are focusing on rates (or quantities) of change, and those which put the emphasis on spatial patterns, implying different data requirements and validation strategies (Velddkamp and Lambin, 2001). Several authors suggest to clearly separate both processes in order to have a comprehensive validation framework (Geist and Lambin, 2001, Pontius and Schneider, 2001) which is not always the case in current land change modeling software. Here, the land change probability maps were transformed into land change allocation maps by assigning the highest probability to change value until the quantity of change is attained, the other values being assigned as no change. Change quantity was defined by simple and explicit expert-decision. The three quantities of area of change scenarios were: the past average, the average past trend projected in the future and other alternative scenarios as presented in tableau 18. Predicted land change allocation maps were constructed independently for each transition and then combined. For non-forest areas in case both land regeneration and land degradation were predicted in the same place, priority was given for regeneration.

2.5 Results & discussion


2.5.1 Observed historical changes

From 2000 to 2014, 24 834 ha (5.76% of the initial forested state) of forest were lost, 38 320 ha (3.41% of the non-forested initial state) of land were degraded and 4 221 ha (0.38% of the non-forested initial state) of land underwent regeneration (tableau 15). The figures of deforestation were corroborated with a recent paper which estimated an annual loss of 1683 ha per year (Rakotomalala et al, 2015) compared to 1 774 ha using Hansen et al (2013) dataset. Regarding forest loss trend we observed a general increase, at a pace of around 200 ha (195 ha) increase in the last fourteen years (figure 27). Land degradation outside intact forest extent was found to be quite important (2 737 ha.y⁻¹) and we observed only a few regeneration areas (302 ha.y⁻¹).

Tableau 15 : Historical land change summary statistics for 2000-2014 period. These statistics were extracted using a combination of datasets from Hansen et al (2013) and Grinand et al (2013).

Land change category	Area of change 2000-2014 (ha)	% of initial state of forest or land	Annual rate of change (ha.y ⁻¹)
Deforestation	24 834	5.76%	1 774
Land degradation	38 320	3.41%	2 737
Land regeneration	4 221	0.38%	302

Figure 27 : Annual deforestation in hectares for the historical period. Values were extracted from forest loss year data product (Hansen et al, 2013) and intact forest extent (Grinand et al, 2013), and smoothed with a moving window of three years.



2.5.2 What are the drivers of deforestation, degradation and regeneration?

Importance of factors was analysed using both empirical and statistical logistic regressions (table 3) in order to visualize and quantify the correlation between observed change and the selected explanatory variables. We first observed a major influence of elevation and distance to the forest for the three land change processes under study (figure 28, figure 29, figure 30). Areas below 700 m of elevation have high risk of deforestation and land degradation. Patterns are less clear for land regeneration displaying two elevation suitability peaks at 110 and 570 m, which is likely to indicate two hot spots of regeneration. In any cases, areas above 700 m are much less threatened of degradation or are much more suitable for regeneration. Proximity to the forest edge effect is clearly a decreasing trend, with high risk of deforestation within 200 m inside the forest, high risk of land degradation within the 500 m buffer around the forest, and close to 800 m for land regeneration. Those two biophysical and proximity local drivers were also recorded to largely influence deforestation in Tanzania (Green et al, 2013).

Slope has no effect on deforestation, contrary to degradation and regeneration which are more likely to occur in steep areas (>8 degrees). This is important to note for land planning intervention as, high slope area may be deforested (slash and burn practices or uncontrolled fire), but are more likely to be abandoned. The effect of slope orientation (aspect) is as one could have expected for the three transitions, with higher suitability for sun facing slope (north), and conversely. This was expected as it indicates that suitable plot for swidden agriculture or plantations have longer sun exposure. The number of dry months seems moderately important, with less suitability values on all transitions over areas with more than four dry months. This applies to the western part of the study area and approximately a third of the study area. Distance to the rivers does not seem to influence any land change transitions. This could be explained by the fact that irrigation is not well developed in these areas, agriculture relies essentially on rain fed crop and that numerous water courses exist over the studied area which hinders its effect detection.

Proximity to main roads and towns show a broad decreasing trend for deforestation risk but with sometimes irregular patterns, it is difficult to interpret. This suggests that main roads and towns have different level of attractiveness. Proximity to villages and tracks is however clearly affecting the probability of deforestation, with high values to 4 kilometers. Regarding land degradation and regeneration, both transitions are affected by the main roads and towns, in a large spatial fringe, from 7 to 30 km. Proximity to villages and tracks has no importance for regeneration, however we observed a slight increase of land degradation in areas at more than 2 km away. We explained this by wood collection for cooking (*kakazo*) or unmanaged bush fire (*dorotanety*) that both occur at short distance from the village. According to the regression analysis (tableau 16), population density is significant despite a low z-value. On figure 3, the relation between deforestation and population density is low with no clear

fashion, for both land degradation and regeneration. This was interpreted as specific local conditions, where population density is not the key factor but expresses here local governance or planning leadership. Finally, the two national parks showed contrasted figures regarding land transition. This will be further addressed in a subsequent section (section 3.5).

Figure 28 : *Driver analysis of deforestation. The dashed line represent the 50% probability, values above indicates high risk of deforestation, values below indicates low risk.*

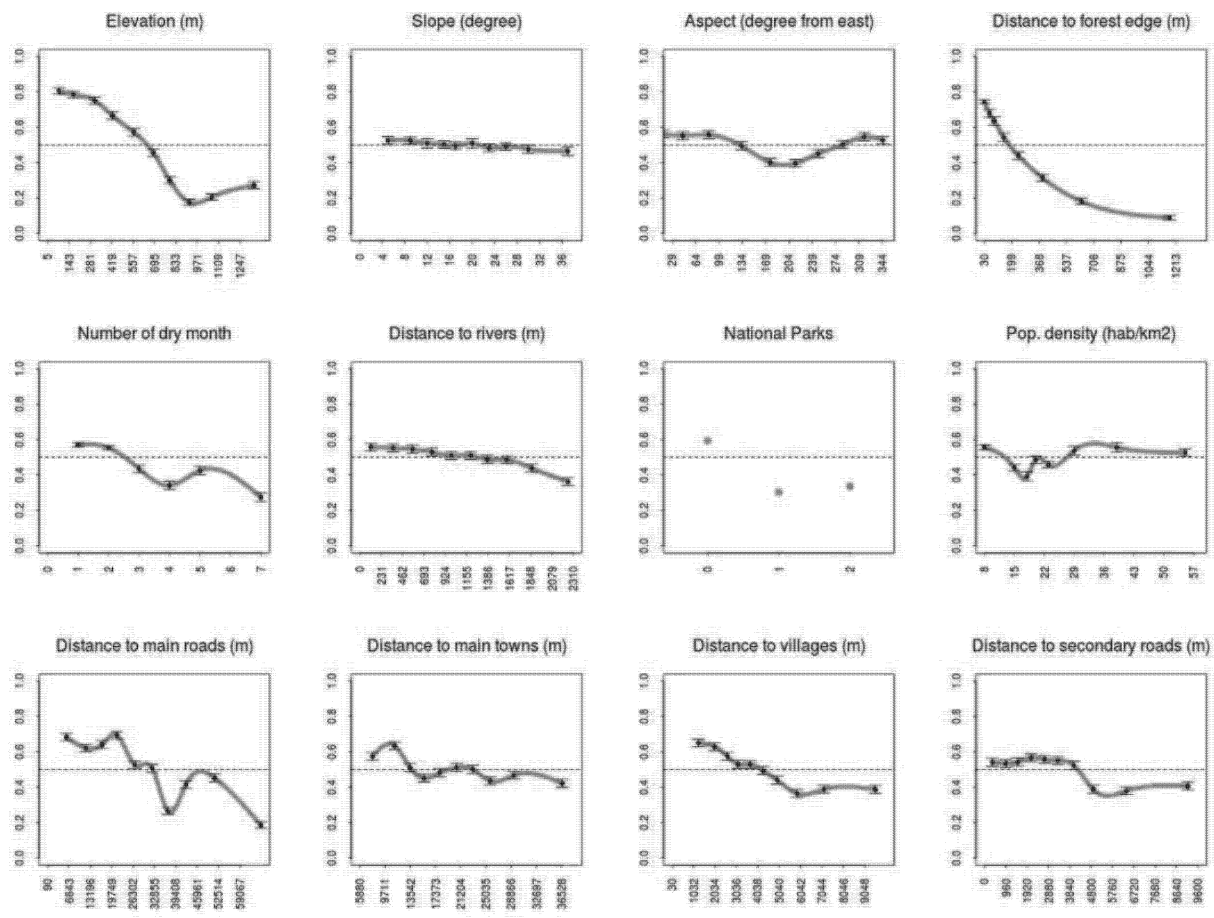


Figure 29 : *Driver analysis of land degradation. The dashed line represent the 50% probability, values above indicates high risk of deforestation, values below indicates low risk.*

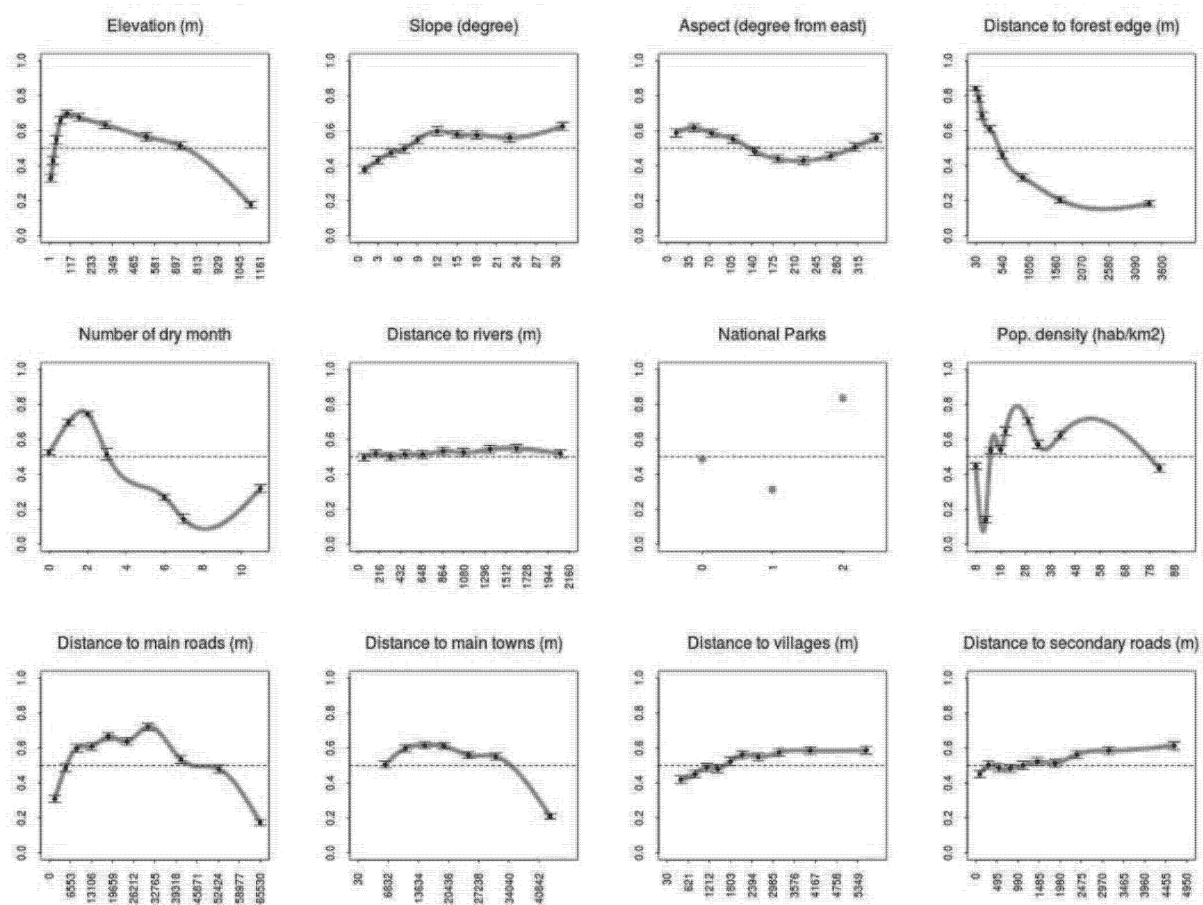


Figure 30 :Driver analysis of regeneration. The dashed line represent the 50% probability, values above indicates high risk of deforestation, values below indicates low risk.

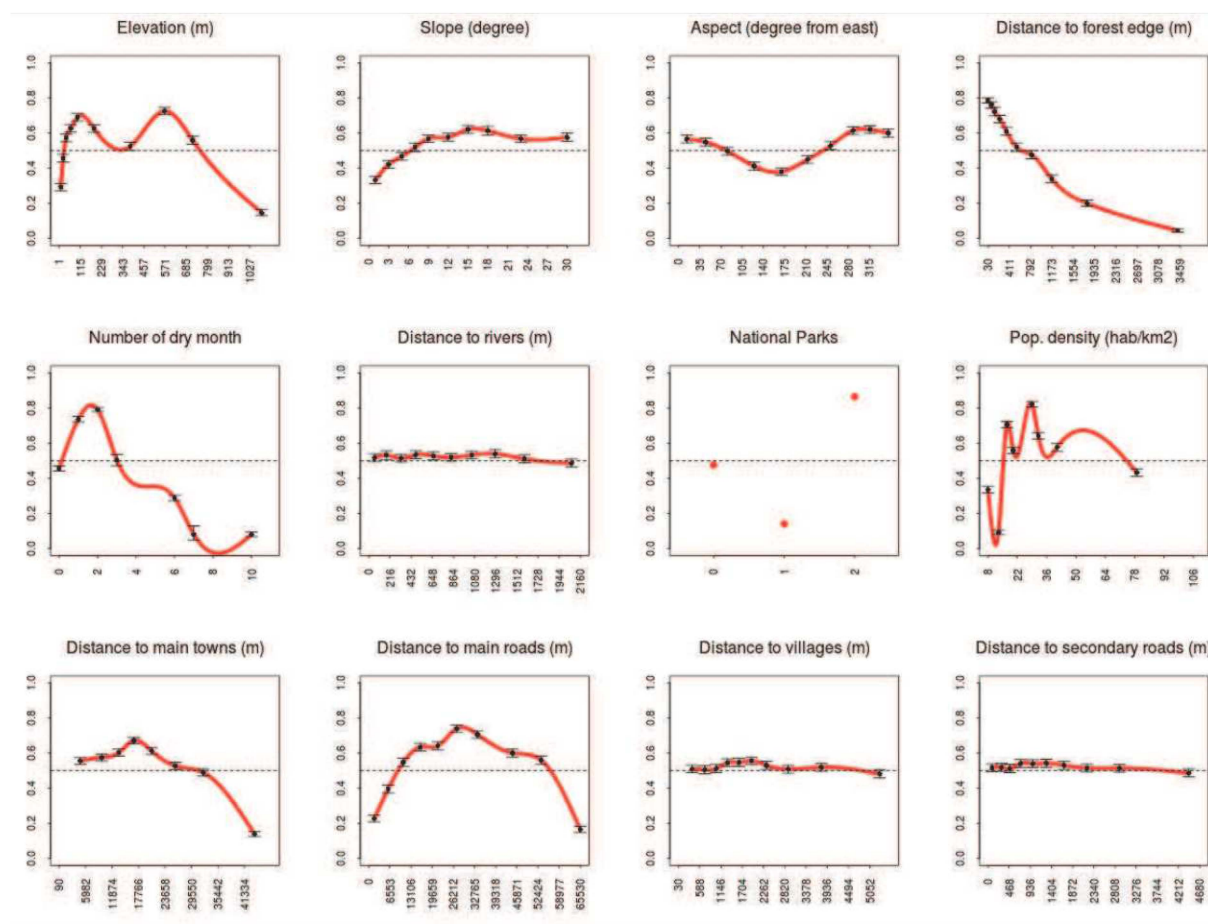



Tableau 16 : Results of linear logistic regression. Sign. Means significativity values of *** 0.001 ** 0.01 * 0.05. Bold values indicates factors with z value above 10.

Factors	Deforestation		Land degradation		Land regeneration	
	z value	Sign.	z value	Sign.	z value	Sign.
Intercept	25.484	***	13.931	***	17.390	***
Elevation	-24.960	***	-23.625	***	-24.199	***
Slope	-1.930	*	11.450	***	13.624	***
Aspect	-8.099	***	-6.161	***	7.031	***
Proximity Forest edge	-36.923	***	-33.613	***	-38.835	***
Number of dry month	-5.782	***	-5.190	***	-23.562	***
Proximity rivers	-0.866		3.933	***	4.839	***
Parks – Andohahela	-0.229		-3.479	***	-3.475	***
Parks – Midongy	-12.394	***	18.210	***	16.967	***
Pop. Density	-3.647	***	-4.018	***	-3.650	***
Proximity main roads	3.577	***	8.932	***	21.505	***
Proximity main towns	5.161	***	-9.044	***	-14.830	***
Proximity villages	-12.675	***	3.592	***	-4.696	***
Proximity tracks	11.944	***	6.136	***	4.171	***

Figure 31 : Illustration of the two main predictors (elevation and distance to the forest edge) effects regarding deforestation, land degradation and land regeneration.



2.5.3 Land change model accuracies

The three calibrated models were applied on an independent sampling validation dataset in order to compute accuracy measurements (tableau 17). We obtained overall accuracy above 75% for the three transitions modeled and all the models which can be considered satisfactory. Nonetheless, as it is a two-class problem with one largely dominant class (no change) this indicator is not particularly relevant. One should rely more on probabilistic or class specific metrics. Basically, the RF model performed systematically better compared to other for the AUC and FOM metrics. AUC was above 0.87 for the three transitions, which means that the three models are much better than a random model. FOM was 0.19 for deforestation, 0.11 for land degradation model and 0.02 for land regeneration model. Contrary to the other indexes, the FOM measure accuracy focusing on the change category and is thus dependent on the observed rate of change (Pontius et al, 2008) which explains the results obtained. Maxent and GLM were slightly better regarding the User Accuracy of Change (UAc) and the Balanced User Accuracy (UA). This highlight the fact that i) RF tends to over predict change in no change observed areas and that ii) Maxent and GLM tend to over predict no change in areas where change were observed. The balanced User Accuracy (here between 0.51 and 0.61) is not a commonly used metrics despite it is seems to us to be a relevant index to assess and compare accuracy between studies and measure our progress in capturing change processes.

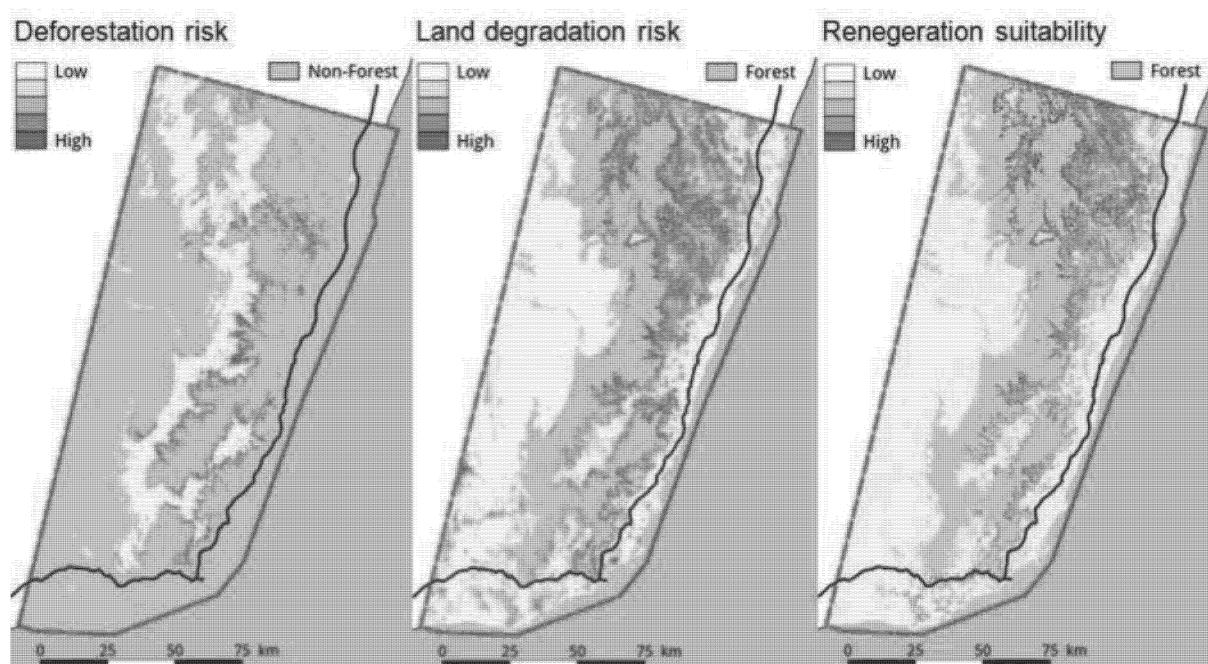
At the end, we selected the RF as the best fit model based on the AUC and FOM results which are well used model in species distribution models (Elith et al, 2006) and land change model (Pontius et al, 2008). Finally, visual inspection of the predicted land change map for

the 2000-2014 periods revealed a broad scale agreement with the observed land change map (supplementary materials).

Tableau 17 : Accuracy assessment results

Land change	Model	AUC	OA	UA _C	UA _{NC}	UA	FOM
Deforestation	RF	0.90	0.78	0.19	0.99	0.59	0.19
	ME	0.84	0.91	0.26	0.95	0.61	0.15
	GLM	0.81	0.91	0.23	0.95	0.59	0.13
Land degradation	RF	0.88	0.75	0.11	0.99	0.55	0.11
	ME	0.84	0.94	0.18	0.97	0.57	0.10
	GLM	0.79	0.94	0.17	0.97	0.57	0.09
Land regeneration	RF	0.93	0.77	0.02	1.00	0.51	0.02
	ME	0.87	0.99	0.06	1.00	0.53	0.03
	GLM	0.86	0.99	0.07	1.00	0.53	0.04

Figure 32 : Illustration of the three land transitions maps



2.5.4 Where is change likely to occur in 2034?

Based on the observed land change (section 1) we developed three usual and easy-to-test scenarios: two business-as-usual (BAU) and one alternative scenario. The first two are considering either a historical average rate of change or the past trends. The past trend was applied only on deforestation (additional 200 ha/y on BAU average) since we do not have any record on the two other transitions evolution rate. The third scenario was discussed with stakeholders and translates an optimistic view considering a 50% decrease of deforestation

and land degradation and considering an important effort of 10 000 ha converted to sustainable land management. The sustainable land management (SLM) here includes activities on the field that increase the vegetation response over years compared to the initial situation. Thus, SLM refers for instance to abandoned land, long crop-fallow rotation, tree plantation or agroforestry. Land change maps under BAU-Average revealed three land change hot spots. First, the forested land which displays the highest risk of deforestation is located in-between the two national parks. A second change area displays land degradation around the south-east forested area and the remaining northern forested patches. Finally, land regeneration area is essentially located in the north area, close to the town of Midongy and neighboring the national Park (figure 33). Projecting the trend of deforestation allowed to characterize larger areas under threat comprising again of the remaining unprotected areas between the two parks but also to all the western side of the humid forest corridor, even within the national parks. The alternative scenario displays reduced patches of deforestation and degradation, and further highlights the northern area to be the best suited location for sustainable land management.

Tableau 18 : Land change quantity scenarios for the 2014-2034 period

Land change transitions	Land change quantity scenario		
	BAU-Average	BAU-Trend	Alternative scenario
Deforestation	1774 ha/y	BAU average +200 ha/y	50% decrease from 2014 level
Land degradation	2737 ha/y	2737 ha/y	50% decrease from 2014 level
Land regeneration	302 ha/y	302 ha/y	BAU average + 10 000 ha sustainable land management

Figure 33 : Land change maps for 2014-2034 period according to the three scenarios

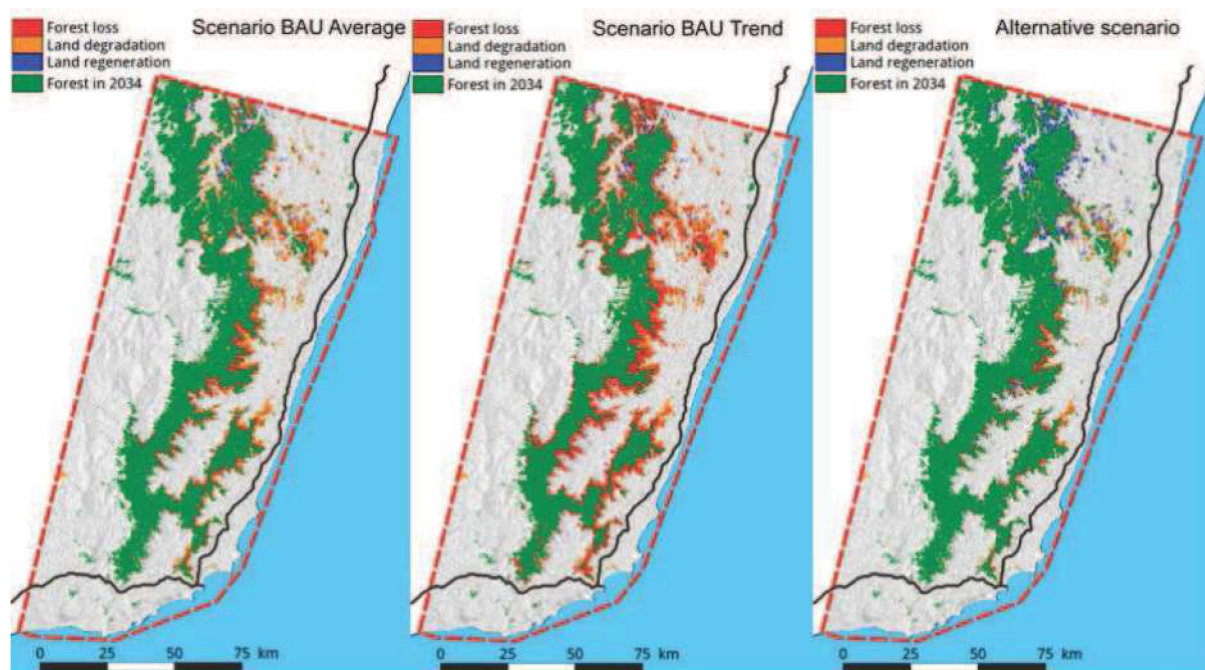
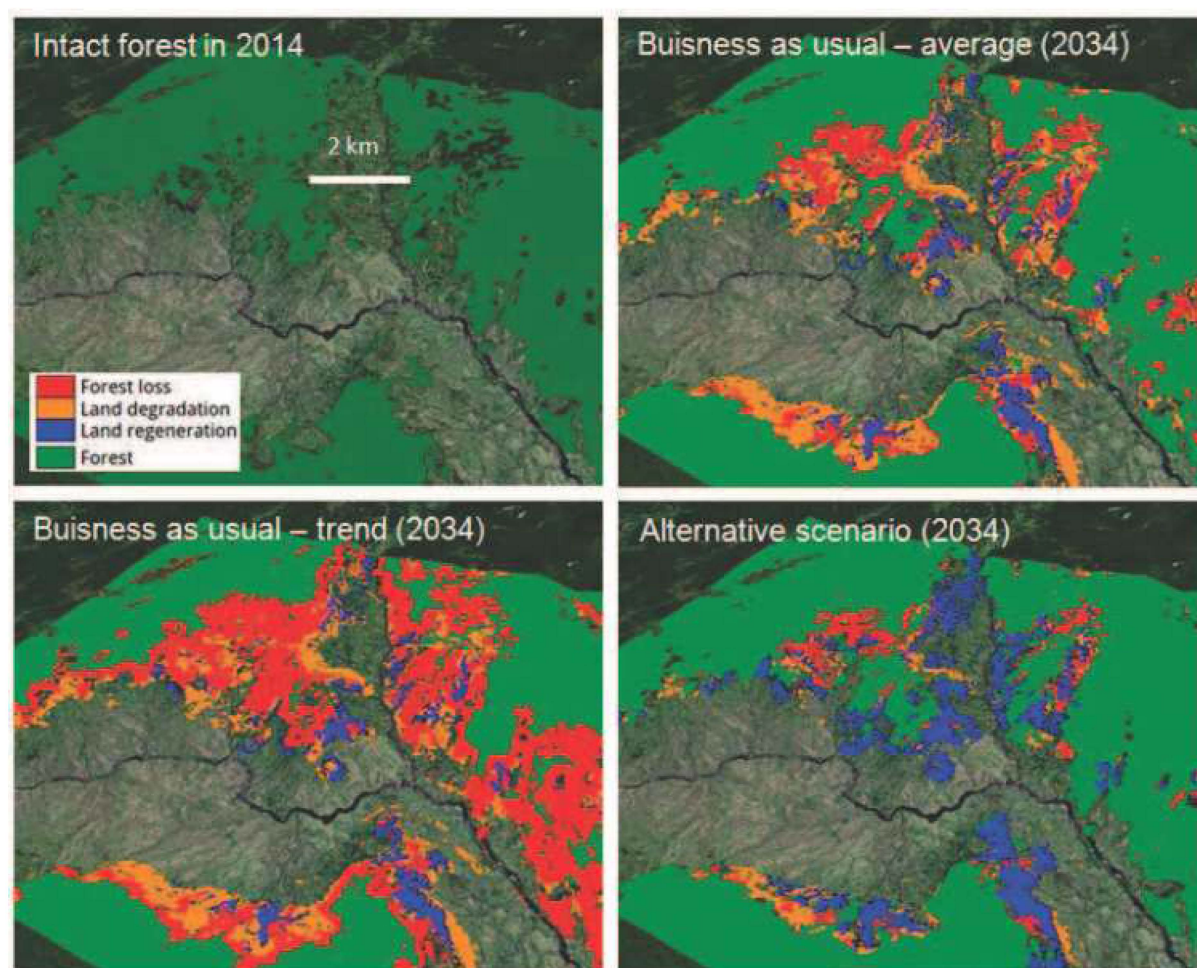


Figure 34 : 3D view of land use change projection for the three scenarios



2.5.5 Conservation threats and development opportunities

As we saw above (section 3.2), the two parks display contrasted figures regarding historical land change process and projection. We further analyzed the effectiveness of those conservation areas by extracting the predicted area of change under the three tested scenarios. We confirmed very contrasted land change dynamic between the two parks. On one hand, the Andohahela National Park is little affected by land change, as we recorded a maximum forest loss of 4 257 ha under the BAU-Trend scenario for the 2014-2034 period (1 107 ha under BAU-Average). On the other hand, the Midongy National Parks displays high figures of change representing more than 10% of its overall area for both BAU scenarios. Deforestation may triple when comparing the average and trend scenario, 5 152 ha and 17 932 ha respectively. On the opposite, the alternative scenario is showing high potential for reduced deforestation, degradation and a clear increase of regeneration (8 253 ha compared to 3 638 under BAUs). Reasons of such differences observed between both national parks include the different historical conservation activity, social and cultural conditions in the neighboring communities. Indeed, Andohahela was created in 1939 contrary to Midongy which was created in 1997, which underline in the meantime the effectiveness of long term conservation activities. On a modeling perspective, this highlight the role of time factor or time feedback involved by such land use predictors. This should carefully be taken into consideration if one want to build scenarios based on change in land tenure or rights (ex. REDD+ project).

The non-protected area is showing important extent of both deforestation and land degradation. Deforestation may represent more than 70 000 ha in 20 years under BAU-Trend scenario. The alternative scenario is offering a small amount of potential land regeneration (8 485 ha), representing only 0.6% of the total non-protected area. This may not reflect the true potential land recovery as one shall recall that our methodology is based on the last fifteen years’ vegetation dynamics. The input dataset is based on simple conversion from no tree cover in 2000 to tree cover in 2012. Longer historical time frame and more precise regeneration definition may highlight more important land regeneration pattern.




Figure 35 : Land change allocation results according to the three scenarios for different extents: the Andohahela National Parks, the Midongy National Parks and outside those two perimeters.

2.5.6 Lessons learned and recommendations for REDD+ baseline development

Spatially explicit land change models are legitimate for their scientific empirical soundness, reproducibility and ability to be assessed by validation procedures (Castella & Verbug 2007). In this study, the use of Random Forest machine learning algorithm was proved to be accurate, despite not entirely robust regarding user accuracy of change. There is no unique good model; machine learning model averaging may provide solution to increase our prediction ability. We saw, as other before (Pontius et al, 2008, Soan and Pelletier, 2012) that the accuracy of the predicted change relies on the change observed. This was observed as regeneration models provided very low FOM values. This shortage could be remediated by increasing the number of years of historical observations (Soan and Pelletier, 2012). Current REDD+ VCS methodology (Shoch et al, 2013) require identifying distinct calibration and validation period, which is our opinion not appropriate as it reduces the number of calibration observations and our ability to understand ongoing changes.

Another limitation arose from the land change definition and pattern recognition. First, land degradation is still not well defined at global or local scale. Here we used a commonly used proxy of removal of vegetation from secondary forest or pixel that used to have trees. Second the gain of vegetation is a slow process and currently available only for 2000-2012 and considers a no-tree cover in 2000. Other definition or dataset of land recovery or land degradation may change the result presented here.

Finally, spatially explicit projection are enable to capture change other that “frontier” change, for instance, deforestation front along the forest edge (Soan and Pelletier, 2012). In this study,

deforestation and degradation were fairly accurately predicted as both process highly relied on the forest edge proxy. Location of regeneration was also partly explained by forest edge which in reality may provide spurious estimate as small scale regeneration may occur far from forest resource. Indeed regeneration potential is steered by forest or agricultural management strategy, at very local scale, in an apparent random manner. Addressing regeneration potential requires more than spatial factors, and deem to understand the socio-cultural and economic drivers, for instance in the reduction in rotation of the crop-fallow length system (Labrière et al, 2016). However, we believe that suitability maps of regeneration may help policy makers and stakeholder to define appropriate landscape scale interventions. There is a great challenge to design appropriate policies that increase the land value on already clear lands, by increasing the agricultural yields or wood production.

2.6 Conclusion

The objective of this paper was to evaluate a novel spatially-explicit land change modeling approach for the simultaneous assessment of three main environmental processes (deforestation, land degradation and land regeneration) in one of the most ecologically rich area in the world.

The results show the high importance of two biophysical and socio-economic factors (elevation and proximity to the forest resource) in explaining the three keys processes. Empirical analysis of the drivers allowed distinguishing numerical threshold values or tipping points that can help local population or stackholders to better identify areas of intervention within the landscape to reduce land degradation and deforestation. Less important but nonetheless significant factors to explained both local scale influence (e.g. local governance, distance to the villages) and regional influence (e.g. distance to main markets and cemented roads).

The land change modeling approach developed in this study is a first attempt to explore the use of open source machine learning tools and global land change dataset in a very practical and land management oriented study. We believe that such an approach can produced reliable and consistent information without over-parameterization, reduced cost, and which could help developing countries to build their own land planning strategies and intervention at multiple scales.

Allocation change or suitability maps are useful for land planner and they can be easily improved as new or better quality input observations are made available. Quantity of change

modeling is still delicate in our point of view and should better be established with stakeholders considering various trajectories and ongoing or future plans.

2.7 Acknowledgments

This research was funded by the French Biodiversity Research Foundation (FRB–FFEM (Fondation pour la Recherche sur la Biodiversité – Fond Français pour l'Environnement Mondial) through the BioSceneMada project (project agreement AAP-SCEN-2013 I) and European Commission through the Roadless Forests project. The first author was funded by an ANRT PhD scholarship (CIFRE N°2012-1153) between Etc Terra association, the Institut de Recherche pour le Développement (IRD), the Centre de Coopération Internationale en Recherche Agronomique pour le Développement (CIRAD) and the Laboratoire des Radio Isotope (LRI).

3 Conclusion de l'étude

En conclusion, nous reprenons les trois problématiques qui ont été posées en introduction :

- **Quels sont les facteurs biophysiques et socio-économiques responsables de la déforestation dégradation des terres et régénération?**

Nos résultats montrent une influence majeure de deux variables : l'altitude et la distance à la lisière de la forêt. Ces deux variables biophysiques et d'accès à la ressource forestière influencent à la fois les processus de déforestation, dégradation des terres et régénération. Les deux premiers processus semblent être limités en altitude, avec des probabilités élevées jusqu'à 700-800 mètres et des probabilités qui chutent plus en altitude. Pour la régénération, des pics de probabilités ont été observés autour de 110 et 570 mètres, vraisemblablement liés à des hotspots de régénération. L'influence de la distance à la lisière est clairement décroissante, avec des probabilités élevées jusqu'à 200 m pour la déforestation, et jusqu'à 500-600 m pour la dégradation des terres et la régénération. La forte influence de ces deux variables a été reportée dans d'autres études à Madagascar (Gorenflo et al, 2010), et en Tanzanie (Green et al, 2013). Ces facteurs permettent de localiser facilement dans le paysage les zones de pression où il faudrait intervenir en priorité.

Nous avons aussi observé que la proximité des villages et pistes affectaient clairement les probabilités de déforestation, jusqu'à 4 kilomètres environ. Pour la dégradation, la tendance est inverse, avec des probabilités qui augmentent progressivement à partir de 2 kilomètres des villages et pistes. Ce résultat semble être lié à la recherche de bois de chauffe et aux passages des feux de brousses, deux activités se localisant à une certaine distance des villages. Pour la régénération ce facteur n'a pas d'effet, laissant penser qu'il s'agit essentiellement de régénération naturelle plutôt que de plantations ou de parcelles agroforestières. Les autres facteurs influencent de manière plus subtile et moins évidente les trois processus étudiés.

- **Est-ce les outils d'apprentissage automatiques (*machine learning algorithm*) permettent d'obtenir de meilleure prédiction comparé aux outils traditionnels de régression linéaire ?**

La comparaison des modèles sur la base d'indicateurs de validation montre un léger avantage pour l'algorithme Random Forest comparé au modèle linéaire généralisé et à Maxent. C'est le cas notamment sur les indices ROC et l'indice Figure of Merit (FOM) qui sont les deux indicateurs les plus utilisés pour évaluer la qualité de ce type de modèle. Au regard des résultats concernant les autres indicateurs, les tendances ne sont pas nettes et soulignent des limites dans l'usage certain indicateur. La précision globale est systématiquement bonne (voire très bonne) du fait d'un grand nombre d'observations sans changement et correctement prédites. Quoi qu'il en soit ces indicateurs sont similaires à ceux reportés sur

une étude similaires dans la région concernant la déforestation (Vieilledent et al, 2012). Nous recommandons donc l’usage de Random Forest pour des applications de modélisation des changements d’usage pour ses capacités prédictives et faible paramétrisation qui permet une réutilisation simple et rapide avec des données d’entrées additionnelles ou actualisées. La comparaison de la qualité des modèles devrait être réalisée également en terme de distribution spatiale dans le paysage afin d’analyser la manière dont le modèle capte les formes des changements (*pattern recognition*).

- **Quelles sont les menaces et opportunités de changements d’usage des terres dans et hors des aires protégées selon différents scénarios ?**

Nous avons enfin pu mettre en évidence d’une part l’effet clair de la réduction de la déforestation grâce au système d’aires protégées de Madagascar. Cet efficacité des aires protégées avait déjà été rapporté par d’autres auteurs (Gorenflo et al, 2010 ; Vieilledent et al, 2013). Ce constat doit encourager les politiques de conservation. Mais il est aussi à nuancer par nos résultats qui montrent de grande différence entre deux aires protégées concernées par cette étude : le Parc National d’Andohahela et et la Parc National de Midongy. Les différences peuvent s’expliquer par un historique très différent entre ces deux réserves. Le premier parc a été créé en 1934 alors que l’autre a été officialisé en 1997. Cela amène à réfléchir sur les questions des temporalités dans l’exercice de modélisation de scénario REDD+, entre l’application de nouvelles régulations - représentées par des polygones - et leurs effets réels. Enfin, les zones non protégées sont les plus affectées par le risque de déforestation et dégradation des terres, avec des surfaces projetées très importantes sur les vingt prochaines années, entre 30 000 et plus de 70 000 ha déforestés en 20 ans selon les scénarios et 40 000 ha de terres dégradées. Sur la zone d’étude, les potentiels de restauration se trouvent cependant à part égale dans les zones non protégées et le parc de Midongy, environ 3000 ha dans le scénario business- as –usual et plus de 8000 ha dans le scénario alternatif. Ces résultats permettent de cibler plus efficacement les sites où les chances de succès de restauration des écosystèmes sont les plus élevées.

4 References du chapitre 4

- Aguilar-Amuchastegui N, Riveros JC, Forrest JL. 2014. Identifying areas of deforestation risk for REDD+ using a species modeling tool. *Carbon Balance and Management*, 9:10. DOI: 10.1186/s13021-014-0010-5
- Baccini A, Goetz SJ, Walker WS, Laporte NT, Sun M, Sulla-Menashe D, Hackler J, Beck PSA, Dubayah R, Friedl MA. 2012. Estimated carbon dioxide emissions from tropical deforestation improved by carbon-density maps. *Nature Clim Change*, 2:182–185.
- Bai Z., Dent D., Wu Y., de Jong R.. 2013. Land degradation and ecosystem services. Chapter 15. 357-381. In R. Lal et al. (eds.), *Ecosystem Services and Carbon Sequestration in the Biosphere*. DOI 10.1007/978-94-007-6455-2_15
- Bax V, Francesconi W, Quintero M. 2016. Spatial modeling of deforestation processes in the Central Peruvian Amazon. *Journal for Nature Conservation*, 29, 2016, 79–88
- Castella JC, Verbug PH. 2007. Combination of process-oriented and pattern-oriented models of land-use change in a mountain area of Vietnam. *Ecological modeling*, 202, 410-420
- Eastman, J.R. 2012. The Land Change Modeler for Ecological Sustainability (chapter 21) IDRISI Selva Manual (version 17). Clark Labs.
- ER-PIN Madagascar, 2015. Emission Reductions Program Idea Note - Testing Emissions Reductions in the rainforest ecoregion. https://www.forestcarbonpartnership.org/sites/fcp/files/2015/September/MDG_ERPIN_English%20with%20annexes.pdf
- Ferretti-Gallon K, Bush J. 2014. What Drives Deforestation and What Stops It? A Meta-Analysis of Spatially Explicit Econometric Studies. CGD Working Paper 361. Washington, DC: Center for Global Development. <http://www.cgdev.org/publication/what-drives-deforestation-and-what-stops-it-meta-analysis-spatially-explicit-econometric>
- Gislason, P.O., Benediktsson, J.A., & Sveinsson, J.R. 2006. Random Forests for land cover classification. *Pattern Recognition Letters*, 27, 294-300.
- Geist HJ, Lambin EF. 2001. What Drives Tropical Deforestation? A meta-analysis of proximate and underlying causes of deforestation based on subnational case study

- evidence. Land-Use and Land-Cover Change International Project Office. Report Series 4. Louvain-la-Neuve, Belgium, 136 p.
- Gorenflo LJ , Corson C, Chomitz KM, Harper G, Honzák M, Özler B. 2010. Exploring the Association Between People and Deforestation in Madagascar. Human Population, 213, pp 197-221
- Green JMH, Larrosa C, Burgess ND, Balmford A, Johnston A, Mbilinyi BP, Platts PJ, Coad L. 2010. Deforestation in an African biodiversity hotspot: Extent, variation and the effectiveness of protected areas, Biological Conservation, 164, 62-72, ISSN 0006-3207, doi.org/10.1016/j.biocon.2013.04.016.
- Grinand C, Rakotomalala F, Gond V, Vaudry R, Bernoux M, Vieilledent G (2013) Estimating deforestation in tropical humid and dry forests in Madagascar from 2000 to 2010 using multi-date Landsat satellite images and the random forests classifier. Remote Sensing of Environment 139, 68–80.
- Harper, G., Steininger M.K., Tucker, C.J., Juhn, D., & Hawkins, F. (2007). Fifty years of deforestation and forest fragmentation in Madagascar. Environmental Conservation, 34, 1-9.
- Hansen, M. C., P. V. Potapov, R. Moore, M. Hancher, S. A. Turubanova, A. Tyukavina, D. Thau, S. V. Stehman, S. J. Goetz, T. R. Loveland, A. Kommareddy, A. Egorov, L. Chini, C. O. Justice, and J. R. G. Townshend. 2013. "High-Resolution Global Maps of 21st-Century Forest Cover Change." Science 342 (15 November): 850–53. Data available on-line from: <http://earthenginepartners.appspot.com/science-2013-global-forest>.
- Hijmans, R. J., Cameron, S. E., Parra, J. L., Jones, P. G., & Jarvis, A. (2005). Very high resolution interpolated climate surfaces for global land areas. International Journal of Climatology, 25(15), 1965–1978
- Huettner M, Leemans R, Kok K, Ebeling J. 2009. A comparison of baseline methodologies for 'Reducing Emissions from Deforestation and Degradation. Carbon Balance and Management, 4,4. DOI: 10.1186/1750-0680-4-4
- IPCC, 2014: Climate Change 2014: Impacts, Adaptation, and Vulnerability. Part A: Global and Sectoral Aspects. Contribution of Working Group II to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change. Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA, 1132 pp

- ONE, DGF, MNP, WCS, Etc Terra (2015). Changement de la couverture de forêts naturelles à Madagascar, 2005-2010-2013. Antananarivo. Madagascar. 21p.
- Pontius Jr, R.G., Cornell, J. and C. Hall. 2001. Modeling the spatial pattern of land-use change with GEOMOD2: application and validation for Costa Rica. *Agriculture, Ecosystems & Environment* 85(1–3) pp. 191–203.
- Pontius, R., W. Boersma, J. C. Castella, K. Clarke, T. de Nijs, C. Dietzel, et al. 2008. Comparing the input, output, and validation maps for several models of land change. *Ann. Reg. Sci.* 42:11–3
- UNEP. 2012. Land Health Surveillance: An Evidence-Based Approach to Land Ecosystem Management. Illustrated with a Case Study in the West Africa Sahel. United Nations Environment Programme, Nairobi. p.211.
- Rakotomala F.A , Rabenandrasana, J. C. , Andriambahiny, J. E. 4 , Rajaonson R. , Andriamalala, F. ,Burren, C. , Rakotoarijaona J.R. , Parany, L. , Vaudry, R. , , Rakotoniaina,S. , Grinand, C. 2015. Estimation de la déforestation des forêts humides à Madagascar entre 2005, 2010 et 2013. *Revue Française de Télédétection et Photogrammétrie*, 211-212, 11-23
- Robin X., Turck N., Hainard A., Tiberti N., Lisacek F., Sanchez JC, Müller M. 2011. pROC: an open-source package for R and S+ to analyze and compare ROC curves. *BMC Bioinformatics*, 12, p. 77. doi:10.1186/1471-2105-12-77
- R-PIN Madagascar, 2008. REDD+ Readiness Project Idea Note – Madagascar. https://www.forestcarbonpartnership.org/sites/forestcarbonpartnership.org/files/Madagascar_FCPF_R-PIN.pdf
- R-PP Madagascar, 2014. REDD+ Readiness Preparation Prosal – Madagascar. <https://www.forestcarbonpartnership.org/sites/fcp/files/2014/August/R-PP%20June%202014.pdf>
- Shoch D, Eaton J, Settelmyer S. 2013. Project Developer’s Guidebook to Voluntary Carbon Standard REDD Methodologies. Conservation International, 97pp.
- Soares-Filho, B.S., Rodrigues, H.O.and W.L.S. Costa. 2009. Modeling Environmental Dynamics with Dinâmica EGO. 115 p. ISBN: 978-85-910119-0-2. Available at: www.csr.ufmg.br/dinamica/tutorial/Dinamica_EGO_guidebook.pdf.

- Sloan S, Pelletier J. 2012. How accurately may we project tropical forest-cover change? A validation of a forward-looking baseline for REDD. *Global Environmental Change* 22 (2012) 440–453
- Veldkamp A, Lambin EF, 2001. Predicting land-use change. *Agriculture, Ecosystems and Environment*, 85, 1–6
- Verburg PH. 2006. Simulating feedbacks in land use and land cover models. *Landscape Ecol* (2006) 21:1171–1183. DOI 10.1007/s10980-006-0029-4
- Vieilledent, G., Gardi, O., Grinand, C., Burren, C., Andriamanjato, M., Camara, C., Gardner, C. J., Glass, L., Rasolohery, A., Rakoto Ratsimba, H., Gond, V. and Rakotoarijaona, J.-R. (2016), Bioclimatic envelope models predict a decrease in tropical forest carbon stocks with climate change in Madagascar. *J Ecol*, 104: 703–715. doi:10.1111/1365-2745.12548
- Weatherley-Singh, J., & Gupta, A. 2015. Drivers of deforestation and REDD+ benefit-sharing: a meta-analysis of (missing) link. *Environmental Science & Policy*, 54, 97–105. <http://dx.doi.org/10.1016/j.envsci.2015.06.017>
- Wehkamp J, Aquino A, Fuss S, Reed EW. 2015. Analyzing the perception of deforestation drivers by African policy makers in light of possible REDD+ policy responses. *Forest Policy and Economics*, 59, 7–18
- Yengoh G.T., Dent D, Olsson L., Tengberg A.E., Tucker C.J. 2014. The use of the Normalized Difference Vegetation Index (NDVI) to assess land degradation at multiple scales: a review of the current status, future trends, and practical considerations. Lund University Center for Sustainability Studies (LUCSUS), and The Scientific and Technical Advisory Panel of the Global Environment Facility (STAP/GEF).

Supplementary Materials

Table S1 : Explanatory variables dataset

Name	Description	Source	Meaning of the pixel value			Algorithm or equation used
			Range	Unit	Meaning	
Elevation	This proxy is related to various other indicators such as the distance from the sea	DEM, SRTM, v4	0-1941	m	Elevation above sea level	Raw data
Slope	Slope intensity may be a constraint for cultivation and selected logging.	DEM, SRTM, v4	0-69	Degree	Slope intensity	Floating window
Aspect	Sun insolation for cropping	DEM, SRTM, v4	0-360	Degree	Orientation of the slope	Floating window
Topographic Wetness Index	Relative soil moisture index due to convergence of water flux and slope effect.	DEM, SRTM, v4	6-26		Wetness index	Log (flow accumulation / slope)
Number of dry month	Number of month where ETP is above rainfall	WORLDCLIM	0-12			
Distance to the main city	This indicator relates to the access of outlets for crop production (market).	BD200 FTM	2,3 - 65	km	Distance at crow flies	Euclidian distance
Distance to villages		BD200 FTM	60 - 17 500	meter		Euclidian distance
Distance to main roads	This indicator relates to people access to commodities (food and material).	BD200 FTM	0 - 65	km		Euclidian distance
Distance to roads and path		BD200 FTM	30 - 13 041	meter		Euclidian distance
Distance to rivers	This indicator relates to water availability for crop production.	Etc Terra, 2016	0 - 3,9	km		Hydrological modeling of streams + Euclidian distance
Distance to forest edge	This indicator describes the accessibility of forest resource	Etc Terra, 2016	30 - 1203	meter		Euclidian distance
Protected areas	It relates to activity regulation defined within the protected areas	SAPM, 2010	0, 1 or 2	Category	0 no parc, 1 Andohahela, 2 Midongy	

Figure S1 : Land change predictors maps

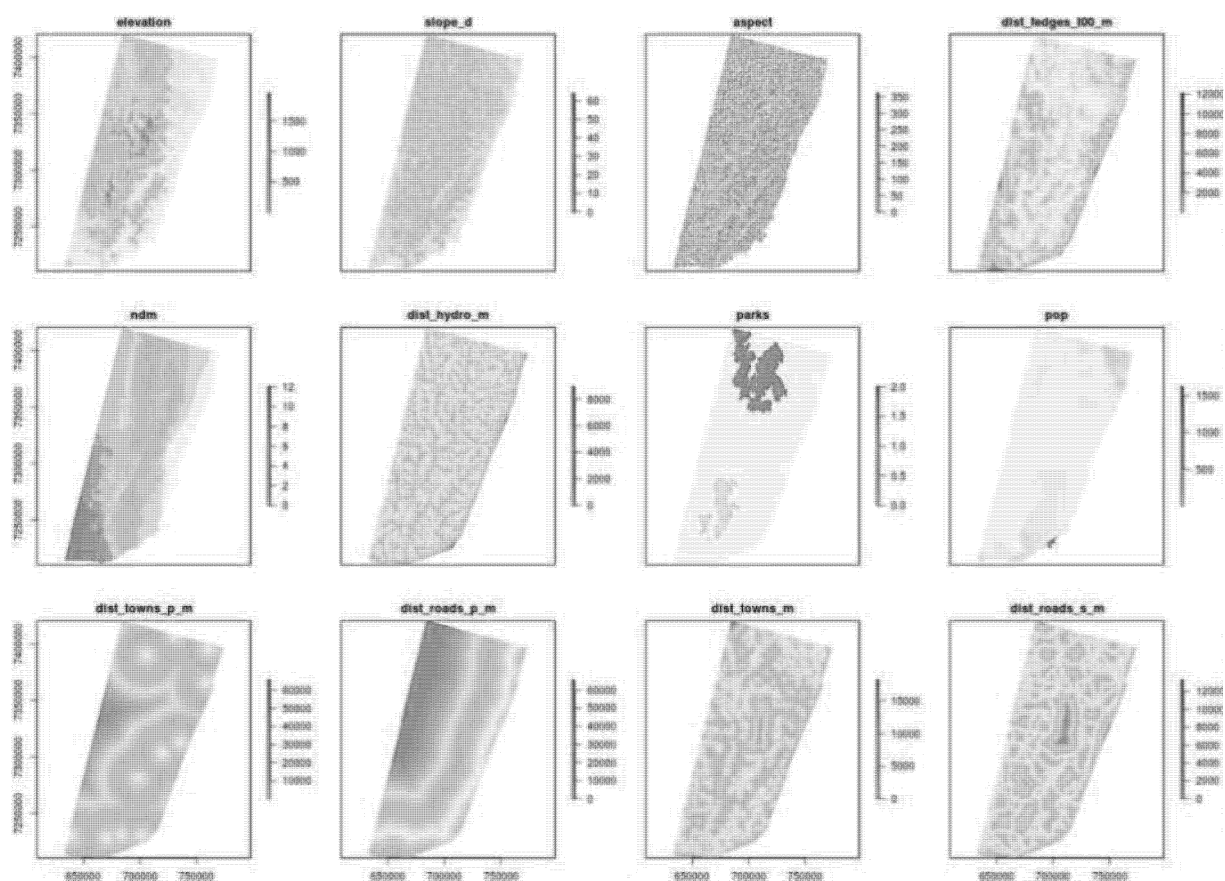
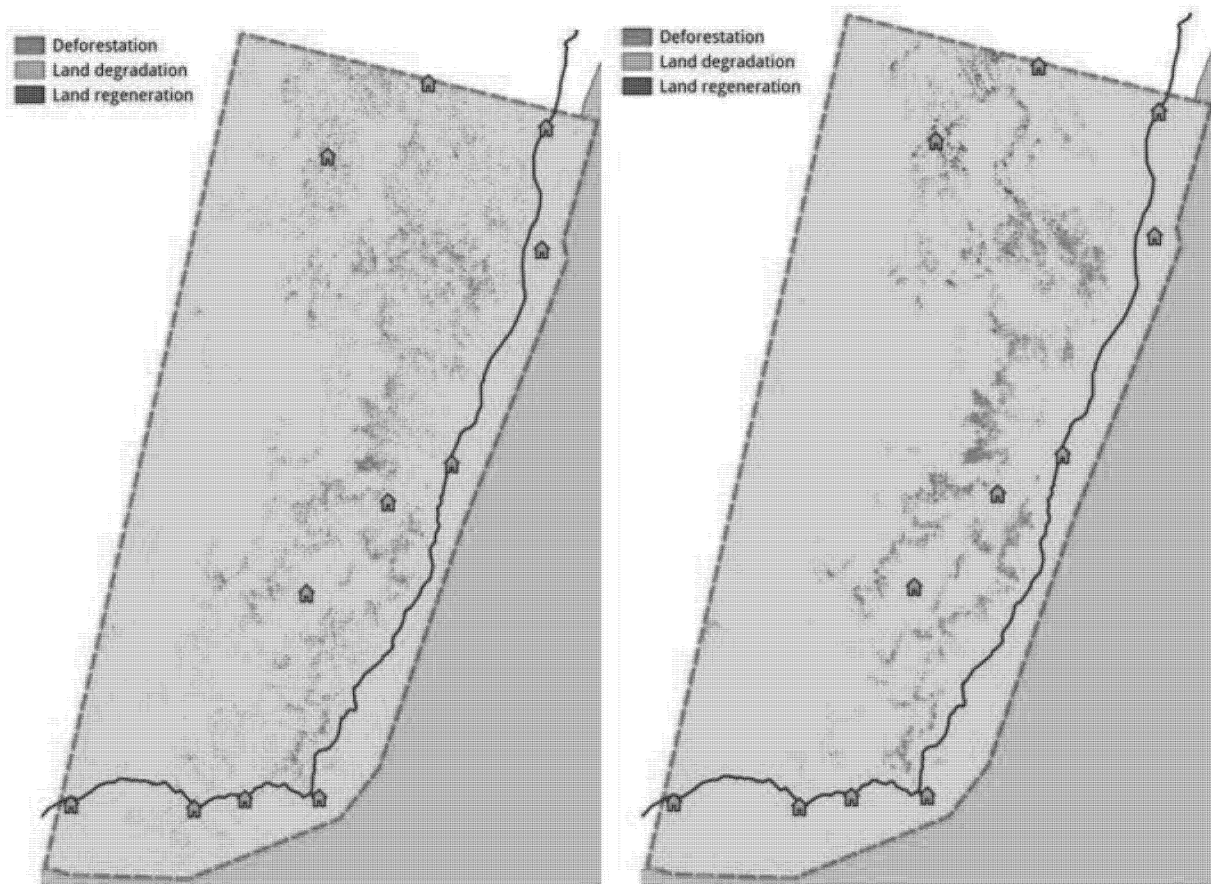


Figure S2: Comparison of 2000-2014 observed land change map (left map) and the predicted land change map (right map)



Chapitre 5 – Conclusion générale

1	SYNTHÈSE.....	162
1.1	RETOURS SUR LES OBJECTIFS DE THÈSE	162
1.2	PRINCIPAUX RÉSULTATS	163
2	DISCUSSION GÉNÉRALE ET PERSPECTIVES.....	166
2.1	CHANGEMENT D'ÉCHELLE ET INCERTITUDES SUR LES ESTIMATIONS	166
2.1.1	<i>Cartographie de la déforestation et du carbone : une question d'échelle ?.....</i>	<i>166</i>
2.1.2	<i>Les études historiques de la déforestation à l'échelle globale sont-elles suffisantes ?.....</i>	<i>168</i>
2.1.3	<i>De l'étude pilote au système national de suivi des forêts</i>	<i>169</i>
2.2	ESTIMER LE CARBONE CONTENU DANS LES DES ÉCOSYSTÈMES TERRESTRES.....	171
2.2.1	<i>Peut-on encore améliorer nos estimations ?.....</i>	<i>171</i>
2.2.2	<i>Vers un suivi de la dégradation et régénération forestière.....</i>	<i>175</i>
2.2.3	<i>Dynamique du carbone à l'échelle paysage.....</i>	<i>177</i>
2.3	MODÉLISER LES CHANGEMENTS D'USAGE DES TERRES : TROP COMPLEXE ?	179
2.3.1	<i>Intensité versus localisation</i>	<i>180</i>
2.3.2	<i>Effet d'échelle versus effet de rétroactions.....</i>	<i>180</i>
2.3.3	<i>Vers des modèles hybrides.....</i>	<i>181</i>
2.4	PERSPECTIVES POUR LA MISE EN ŒUVRE DE LA REDD+ À MADAGASCAR	184
3	CONCLUSION.....	186
4	RÉFÉRENCES DU CHAPITRE 5	187

“Information sharing is the bottleneck of efficiency decision making, not the tool”

(Anonyme)

1 Synthèse

1.1 Retours sur les objectifs de thèse

Pour rappel, l'objectif de la thèse était d'**améliorer les estimations des émissions ou séquestrations de CO₂ associées à la déforestation, dégradation et régénération des terres à l'aide de méthodologies innovantes**. La finalité de cette thèse est i) de contribuer à une meilleure gestion des écosystèmes par la fourniture d'information spatiales justes, précises et utilisables à différentes échelles, et ii) de pouvoir faire évoluer les outils et méthodes utilisées dans les projets, programmes ou politiques REDD+.

Nos objectifs étaient à la fois thématiques et techniques.

Objectifs techniques

- Développer une méthodologie fiable, précise et reproductible permettant le suivi de la déforestation de petites surfaces forestière sur de grandes superficies ;
- Elaborer des modèles de distribution de carbone organique dans les sols pour deux profondeurs de sols à partir des facteurs spatialisés de pédogénèse ;
- Prédire des scénarios spatialisés de déforestation, dégradation des terres et régénération afin d'aider les décisions et la planification territoriale.

Objectifs thématiques

- Actualiser les chiffres de la déforestation sur la région des forêts humides de Madagascar ;
- Estimer les gains et pertes des stocks de carbone dans le sol à l'échelle des paysages ;
- Analyser les causes de la déforestation, dégradation des terres et régénération afin de mieux comprendre ces processus.

Afin d'atteindre ces objectifs notre travail s'est principalement appuyé sur

- Des campagnes de terrain afin de réaliser un inventaire de sol, des enquêtes et des observations pour la validation des résultats
- Des analyses de sol en laboratoire (au Laboratoire des Radio Isotopes à Antananarivo)
- La collecte, préparation et traitements d'un grand nombre de variables environnementales, essentiellement à partir de satellites d'observation de la Terre et leur manipulation avec des logiciels Système d'Information Géographique (les principaux logiciels informatiques utilisés pour cette partie du travail étant QGis et Grass).

- L'utilisation d'outils statistiques et de modélisation en particulier le logiciel R et l'algorithme « Random Forest » afin de suivre la déforestation, estimer les stocks de carbone dans le sol et prédire les scénarios de changements d'occupation et d'usage des terres.
- Une revue systématique de la littérature
- La participation à des projets et programme de recherche-action et développement rural

Les travaux que nous avons réalisés ont été présentés sous la forme de trois articles visant des revues internationales à comité de lecture : deux ont été publiés, un autre a été soumis. Nous nous sommes attaché à suivre une démarche visant à améliorer et enrichir l'établissement de scénarios d'émissions de carbone, du paysage à l'échelle régionale, à travers le suivi de la déforestation (Chapitre 2), l'estimation des stocks de carbone organique et leur évolution passée (Chapitre 3) et la modélisation des changements d'usages des terres (Chapitre 4).

Cette thèse sous Convention Industrielle de Formation par la Recherche (CIFRE) entre l'Institut de la Recherche pour le Développement et l'Association Etc Terra s'est inscrite dans un programme de recherche-action plus vaste, en collaboration avec différentes équipes de recherche et acteurs du développement territorial. Quatre autres études rédigées en tant que co-auteur et en lien avec le sujet de ma thèse ont été publiées et sont présentées en Annexe.

La section suivante revient sur les principaux résultats des trois études présentées dans ce manuscrit.

1.2 Principaux résultats

Nous avons développé une nouvelle méthodologie de traitements de données satellites pour le **suivi de la déforestation à Madagascar**. Cette méthodologie s'appuie sur un travail intense de photo-interprétation à partir de séries temporelles d'images Landsat et images disponibles sur Google Earth et traitées numériquement avec l'algorithme *Random Forest*. Une évaluation rigoureuse de la qualité des cartographies produites a été réalisée à partir d'un effort important d'inspection visuelle (30 000 points) et a montré que les classes « stables » de forêt et savanes avaient des précisions utilisateur de 84,7% et les classes « dynamiques » de déforestation entre 2000-2005 et 2005-2010, des précisions de 60,8%. Cette méthodologie a fourni des chiffres actualisés de la déforestation entre 2000 et 2010 à l'échelle régionale. Ses caractéristiques « open source » (données et logiciels) permettent un changement d'échelle, une reproductibilité et appropriation par les acteurs locaux. Suite à la publication de l'étude, la méthodologie décrite dans cette thèse a été appliquée sur tout le pays pour la période 2005-2013 afin d'alimenter la stratégie REDD+ de Madagascar et identifier les zones prioritaires de lutte contre la déforestation.

Nous avons également proposé une méthodologie de **cartographie de stocks de carbone du sol et de leurs changements passés** à l'échelle régionale. Dans un premier temps, une analyse des facteurs déterminants du stockage du carbone sol et une cartographie régional en 2010 a été réalisée. Elle a permis de montrer l'influence des variables climatiques (précipitation et température annuelle) et géologiques (radiométrie gamma) sur les gradients régionaux de stocks de carbone et, plus localement, l'influence des variables sol, végétation et topographie. Le modèle calibré des données satellites acquises en 2010 a été appliqué sur des images d'archives acquises en 1990 afin de prédire les stocks à cette époque et les comparer à ceux actuels. Des étapes de post-traitements ont été introduites afin de réduire les biais liés à l'extrapolation dans le temps et l'espace, réduisant de 64% la quantité d'information sur le territoire étudié. Le résultat obtenu indique que 10% du territoire étudié (47 287 ha) a subi des changements significativement différents de zéro (gains ou pertes) au cours de la période 1991-2011. Le croisement de cette cartographie avec les parcelles de déforestation montre des pertes potentielles de -10,7 et -5,2% pour les 30 et 100 premiers centimètres de sol respectivement, en région humide. Cela correspond à 8,8 et 7,6 MgC.ha⁻¹.an⁻¹ de perte en moyenne sur la période 1991-2011. Nous n'avons pas enregistré de changements significatifs pour les sols en région sèche. La cartographie régionale des gains et pertes de carbone ainsi produite permet d'identifier les zones dégradées ou en cours de restauration, à des résolutions fines et pour des étendues régionales.

Nous nous sommes enfin intéressés à la **modélisation des changements d'usage des terres et à l'élaboration de scénario** pour les vingt prochaines années. Une analyse empirique de l'influence des facteurs de changement a montré l'importance de deux variables biophysiques et d'accès à la ressource forestière pour expliquer les processus de déforestation, dégradation des terres et régénération : l'altitude et la distance à la lisière forestière. Nous avons aussi observé que la proximité des villages et pistes affectaient clairement les probabilités de déforestation, jusqu'à 4 kilomètres. Les autres facteurs influencent de manière plus subtile et moins évidente les trois processus étudiés. L'utilisation de l'algorithme d'apprentissage automatique Random Forest a permis d'obtenir des résultats satisfaisants, comparé à d'autres algorithmes (Maxtent, modèle logistique). Nous avons ensuite élaboré des scénarios de quantité de changement (superficie), à partir des observations de changement passés (moyenne ou tendance historique) et scénario alternatif plus optimiste (réduction de la déforestation, diffusion de pratiques maintenant un couvert végétal arboré). Ces valeurs d'intensité de changement ont été appliquées sur les cartes de probabilités de déforestation, dégradation des terres et régénération. Nous avons observé, comme d'autres études avant nous, l'effet positif des aires protégées pour réduire la déforestation, mais qui varie grandement selon la date de création des parcs. Les zones non protégées sont les plus affectées par le risque de déforestation et dégradation des terres, avec des surfaces projetées très importantes sur les vingt prochaines années, entre 30 000 et plus de 70 000 ha déforestés

en 20 ans et 40 000 ha de terres dégradées. Les potentiels de restauration se trouvent à parts égales dans les zones non protégées et le parc de Midongy (environ 3000 ha dans le scénario « moyenne historique » et plus de 8000 ha pour le scénario alternatif). Cette étude permet de proposer des scénarios spatialement explicites pour la construction de scénario ou niveaux d'émissions de GES prenant en compte les gains et les pertes (émissions « nettes »), et permet de cibler plus efficacement les sites d'interventions des politiques de gestion des terres.

2 Discussion générale et perspectives

2.1 Changement d'échelle et incertitudes sur les estimations

2.1.1 Cartographie de la déforestation et du carbone : une question d'échelle ?

Au départ, en 2012, cette thèse a été réfléchi pour répondre aux enjeux liés aux questions d'échelles et changement d'échelle : « comment évaluer précisément l'état de l'environnement (notamment à travers l'indicateur environnemental qu'est le carbone organique des sols) à différentes échelles : locale, régionale et nationale ? » À chacune de ces échelles correspondent des enjeux différents (ex. la gestion de la fertilité à l'échelle de la parcelle, l'aménagement du territoire à l'échelle régionale, le plan d'action climat à l'échelle nationale) ainsi que des données d'entrée et potentiellement des méthodes différentes. Au cours de la thèse, nous avons fait le constat que cette question - malgré ses enjeux communs et un intérêt opérationnel - n'était plus une question *fondamentale* de recherche.

Tout comme Google Earth en 2005 a révolutionné l'accès aux informations géographiques à l'échelle du monde, l'étude de Hansen et ses confrères en 2013 ont révolutionné l'accès aux informations sur la déforestation et constitue un bond en avant en termes de techniques de télédétection (figure 36). C'est la première fois qu'une étude réussit à traiter autant d'images satellites à l'échelle mondiale (12 années d'archives de 2000 à 2012 et plus 143 milliards de pixel Landsat par année). Cela offre un accès compréhensible pour le grand public à travers la plateforme Global Forest Watch (GFW, www.globalforestwatch.org). L'information sur la perte du couvert arboré (*tree cover loss*) est actualisée tous les ans avec les mêmes outils et elle est mise en ligne sur la plateforme GFW. Le gain en couverture arborée n'est pas quant à lui actualisé compte tenu de la lenteur de ces changements. Malgré de fortes critiques sur ces résultats, (Tropea et al, 2014 ; Belon et al, 2014), cette étude ouvre la voie à la production d'informations environnementales « *globally consistent and locally relevant* ».

Concernant le carbone contenu dans les arbres et dans le sol, la tendance est identique. Les cartes de biomasse aérienne mondiale ont déjà des résolutions de 500 mètres (Saatchi et al, 2011) ou 1 km (Baccini et al, 2012 ; Avitabile et al, 2016). L'utilisation des séries temporelles Landsat mondiales pour produire des cartes de biomasse à 30 m de résolution devrait voir le jour très prochainement. Le sol n'en est pas moins mis à l'écart. Les progrès en cartographie numérique des sols présentés dans le chapitre 2 et l'existence de bases de données mondiales sur les sols permettent d'envisager la création de cartes mondiales des propriétés du sol à 30 ou 90 mètres de résolution (Sanchez et al, 2014). C'est l'objectif du programme Global Soil Map (www.globalsoilmap.com) qui regroupe tous les experts sur le sujet. Dans cet esprit une

plate-forme mondiale (www.soilgrid.org) a récemment été lancée et propose de nombreuses cartographies des propriétés du sol à 1 km (Hengl et al, 2014) et 250 m (Hengl et al, in review).

La question d'échelle semble aujourd'hui plus politique que scientifique, car il est facile d'agréger des données très hautes résolutions à des paysages, écorégion ou niveaux administratifs par l'utilisation de statistiques simples (moyenne, médiane ou vote majoritaire). Cependant, derrière ces avancées, qui permettent de mieux comprendre les enjeux environnementaux, se cachent encore beaucoup d'incertitudes, de défis scientifiques et technologiques.

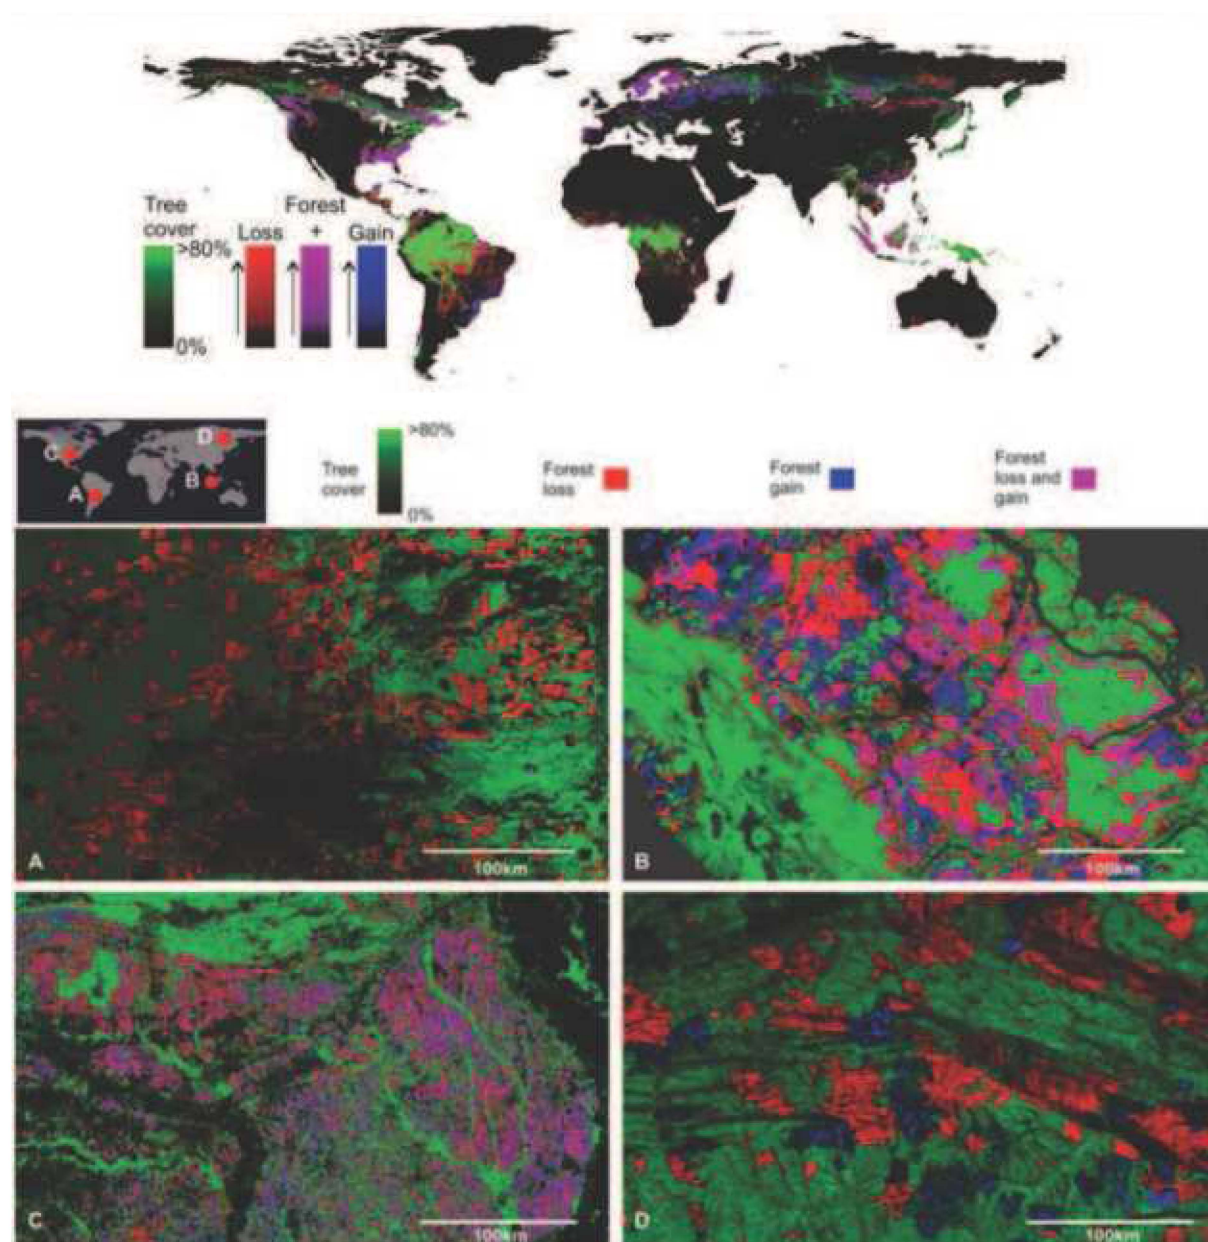


Figure 36 : Illustration de la « carte de Hansen ». Carte mondiale des changements de couverture arborée pour la période 2000-2012. Extrait de Hansen et al, 2013.

2.1.2 Les études historiques de la déforestation à l'échelle globale sont-elles suffisantes ?

Le chapitre 1 présenté dans cette thèse est une étude similaire à celle de Hansen et al (2013) sur plusieurs points : elle utilise directement la série temporelle d'image Landsat (approche « multi-date » ou méthode de détection de changement dite de « pré-classification »), traite les données à partir d'arbres de décision, et produit des estimations de perte du couvert forestier sur la dernière décennie. Cependant notre étude et celle d'Hansen restent très différentes sur plusieurs aspects.

L'étude d'Hansen est basée sur une analyse automatique des données satellites Landsat, après correction atmosphérique et standardisation des réflectances, tandis que le modèle utilisé dans la présente étude ne s'appuie sur aucune correction radiométrique particulière (niveau de prétraitement L1T des images Landsat) et a été calibré avec des parcelles d'entraînement. Dans notre étude, des parcelles de forêt intacte et parcelles défrichées ont été identifiées par photo interprétation et vérifiées sur des images présentes dans Google Earth. Cela permet de s'assurer de la définition de la forêt pour les forêts restantes et d'identifier celles qui ont été converties en champ de culture ou pâturage/savane à cause du feu. Par ailleurs, l'étude d'Hansen précise qu'il s'agit d'une détection de perte de « couverture arborée » (*tree cover loss*) caractérisé par la présence d'arbres de plus de 5 mètres à l'échelle du pixel. Il est cependant impossible de s'assurer de la hauteur des arbres par des traitements de données optiques. Les problèmes de définition de la forêt dans cette étude ont été soulevés par certains auteurs (Achard et al, 2014), et ont été tenus pour responsable à la fois de sous-estimation (Tropec et al, 2014) ou sur-estimation (Belon et al, 2014) de la déforestation. Il semble par ailleurs que la détection de la déforestation en Afrique de l'Ouest soient largement sous-estimée (communication personnelle).

Par ailleurs, Hansen et al (2013) produit une carte des pertes *par année* (*forest loss year*), avec une tolérance de plus ou moins une année (Potapov, communication personnelle) afin d'obtenir des pixels sans nuage. Une déforestation enregistrée pour l'année 2010 peut ainsi correspondre à une déforestation en 2009 ou 2011 en réalité. D'un point de vue de l'utilisateur, il est donc impossible de connaître la date exacte de la conversion d'usage. Ceci peut poser des problèmes importants lors des calculs de taux de déforestation sur des intervalles de temps de quelques années (Vieilledent et al, 2012).

Néanmoins, à l'échelle d'un pays comme Madagascar, le Global Forest Watch reflètent bien la tendance de l'évolution de la couverture forestière. A l'échelle régionale ou du paysage, ces données doivent être considérées avec précaution et vérifiées. Elles ne peuvent en effet remplacer une étude de télédétection dont les images satellites utilisées sont connues et dont la calibration de l'algorithme est réalisée avec des connaissances du terrain.

Enfin, comme on l'a mentionné en introduction, les pays engagés dans la REDD+ doivent mettre en place un système de suivi national des forêts (système de Suivi Notification Vérification - SNV). Ces études de suivi de la déforestation par télédétection sont donc nécessaires et doivent être menées par les acteurs locaux (ex. services techniques forestiers, organismes parapubliques d'observation de l'environnement) qui connaissent leur territoire et sont les premiers utilisateurs.

2.1.3 De l'étude pilote au système national de suivi des forêts

Le chapitre 1 de cette thèse présente une étude pilote sur le suivi de la déforestation adaptée au contexte malgache (région tropicale et déforestation principalement liée au défriche brûlis pour de la culture de subsistance). En 2013, une assistance technique auprès de l'Office National pour l'Environnement (ONE) a comparé cette méthode (Grinand et al, 2013) et celle qui a été utilisée pour l'étude sur l'historique de la déforestation de la période 1990-2000-2005 (MEFT, 2009). Les résultats montrent plusieurs avantages pour la première étude dont i) l'usage intensif et raisonné de la photo-interprétation couplé à l'algorithme Random Forest offre une plus grande précision et ii) l'utilisation de post traitements à 0,36 hectares pour les parcelles de déforestation permettant de ne pas sous-estimer la déforestation (données non publiées, Atelier ONE-DGF, HELVETAS-CIRAD. 2013). Elle a ensuite été mentionnée dans les documents cadre de la stratégie nationale REDD+ (RPP Madagascar, 2014, méthode « PHCF »), appliquée à l'échelle de l'écorégion des forêts humides (Rakotomalala et al, 2015) puis étendue à Madagascar par un consortium d'acteurs nationaux (ONE, DGF, MNP, WCS, EtcTerra, 2015) sur la période 2005-2010-2013 dans le cadre du Programme Ecorégional REDD+ des Forêts Humides de Madagascar (PERR FH).

L'étude de Rakotomalala et al (2015, Annexe 1 ; figure 37) a finalement démontré la possibilité d'utiliser cette méthode à plus large échelle (>20 millions d'hectares) tout en réduisant l'intervalle de temps de suivi : de 5 ans en moyenne (Grinand et al, 2013) à 3 ans (Rakotomalala, et al, 2015). La validation a été réalisée de la même manière (observation visuelle) sur la base de données satellites externes (SPOT 5) collectées grâce à la station de Surveillance de l'Environnement Assistée par Satellite pour l'Océan Indien (SEAS-OI). Elle a montré des précisions de 75% pour les catégories de changements (déforestation) et plus de 88% pour les catégories sans changement. Les résultats sont alarmants : la superficie des forêts humides de l'Est de Madagascar a ainsi diminué de 4 555 788 hectares en 2005 à 4 345 093 hectares en 2013. Cela correspond à un doublement du taux de déforestation, de 0,5%/an (21 710 ha/an) à 0,9%/an (34 567 ha/an) entre les deux périodes étudiées (2005-2010 et 2010-2013).

Actuellement, la stratégie REDD+ National est piloté par le Bureau National de coordination REDD+ (BNC REDD+), en phase de préparation sur tous les sujets concernant la REDD+

(analyse des facteurs de la déforestation, niveau de référence des émissions, plan d'action détaillé, gouvernance, garanties/sauvegardes, gestion des plaintes, partage des revenus, etc.). En parallèle, le gouvernement de Madagascar a récemment proposé une note d'intention pour développer un programme de réduction des émissions à l'échelle sous-régionale au niveau des forêts humides de l'est (ER-PIN, 2015) qui devrait se traduire par une proposition de programme (ER-PD) en septembre 2017 – tout comme de nombreux autres pays – auprès du FCPF.

Malgré les avancées notables en termes de préparation à la REDD+ et particulièrement d'un point de vue de la mise en place d'un système de suivi de la déforestation à Madagascar, des enjeux méthodologiques persistent.

- **Actualiser le suivi de la déforestation.** La dernière évaluation (ONE, 2015) présente l'état des forêts jusqu'en 2013 (+ ou – 1 an). Or, le rythme de la déforestation étant un des plus hauts du monde (Achard et al, 2002), dans un contexte d'endémisme très élevé, il est conviendrait de réaliser un autre historique sur la période 2013-2015 afin de mieux comprendre les dynamiques et causes récentes.
- **Intégrer les autres types de forêts.** Pour l'instant seules les forêts intactes sont suivies. Dans l'optique de faire un état de lieux complet des forêts, il est nécessaire d'intégrer les forêts secondaires (régénération naturelle ou vieille jachère) et les plantations (ex. eucalyptus ou pins). Il existe plus de 140 000 hectares de plantation d'eucalyptus à Madagascar et leur rôle tant l'économie national et que pour la préservation des massifs de forêt naturelle intacts est très important (Randrianjafy, 1999).
- **Prendre en compte la dégradation des forêts.** Souvent considéré comme faible en termes d'hectare et d'émissions de CO₂, il n'en demeure pas moins que la coupe illégale de bois précieux à Madagascar est une problématique environnementale (et politique) majeure (Divay, 2014). Seules quelques études exploratoires se sont intéressées à la dégradation des forêts à Madagascar (Alnutt et al, 2013).

Deux limites viennent freiner ces trois améliorations envisagées du système de suivi et leur cartographie à l'échelle nationale : la résolution des images Landsat et la disponibilité d'images sans nuage au cours de l'année. Le nouveau capteur SENTINEL 2A, lancé en avril 2015 et délivrant des images depuis septembre 2015, offre une opportunité sans précédent pour lever ces barrières technologiques. Les images SENTINEL 2 sont des images optiques à des résolutions de la taille de la canopée d'un arbre (10 mètres) et mises à disposition gratuitement par l'Agence Spatiale Européenne (ESA). Le lancement prévu du satellite SENTINEL 2B en 2017 devrait offrir une fréquence d'acquisition tous les cinq jours en tout

point du globe. Une des questions techniques qui va se poser prochainement, sera la comparaison des statistiques forestières obtenues avec les données Landsat et celles obtenues avec des données SENTINEL. Comme on a pu le constater dans cette thèse, le fait de diminuer l'unité minimum de cartographie (UMC) tend à augmenter les surfaces détectées comme déforestées. Cela pose alors la question de **l'intégration des données SENTINEL dans le système de suivi national**, afin de garantir la compatibilité avec les études précédentes.




Figure 37 : Carte de l'histoire de la déforestation dans l'écorégion humide de l'Est de Madagascar avec un zoom sur une zone à forte intensité (hot spot) de déforestation. Extrait de Rakotomalala et al, 2015

2.2 Estimer le carbone contenu dans les des écosystèmes terrestres

2.2.1 Peut-on encore améliorer nos estimations ?

La grande disponibilité de données environnementales et notre capacité à les traiter (puissance de calcul et algorithme), nous permet aujourd'hui de réaliser des objectifs ambitieux de cartographie carbone à large échelle avec des résolutions fines (paragraphe 2.1). Mais ces cartographies sont-elles suffisamment justes et précises ? La précision des résultats est souvent considérée comme tributaire des données d'inventaire terrain, en particulier de leur

localisation et leur densité (Minasny et al, 2013 ; figure 40). Les données satellites peuvent elles nous affranchir de ces couteux et fastidieux travaux de terrain ?

À l'échelle globale ces deux cartes pan-tropical de la biomasse (Saatchi et al, 2011 ; Baccini et al, 2012) produisent des résultats similaires lorsque l'on considère le stock total de carbone contenu dans les arbres (Mitchard et al, 2013). Néanmoins, à l'échelle du pixel, cette étude montre qu'il est très fréquent d'avoir plus de 100% d'écart entre les différentes études. Des différences de plus de 50 tC/ha ont été observées entre ces cartographies et celle produite à partir de données d'inventaire et couverture LiDAR sur le bassin amazonien. De plus, Avitabile et al (2016) montrent que les deux cartes avaient surestimé de 9 à 18% respectivement les stocks de carbone totaux en comparant avec des données de référence non utilisées dans ces études (figure 38). Pour expliquer cela, de nombreuses sources d'erreurs sont avancées, incluant le jeu de données de validation lui-même. Elles se situent au niveau de l'inventaire (relevé terrain, méthode de calcul des stocks), au niveau spatial (géolocalisation des placettes, sous et sur représentation, cf figure 38) et temporel (décalage entre les dates d'inventaires, entre eux et avec les données spatiales utilisées).

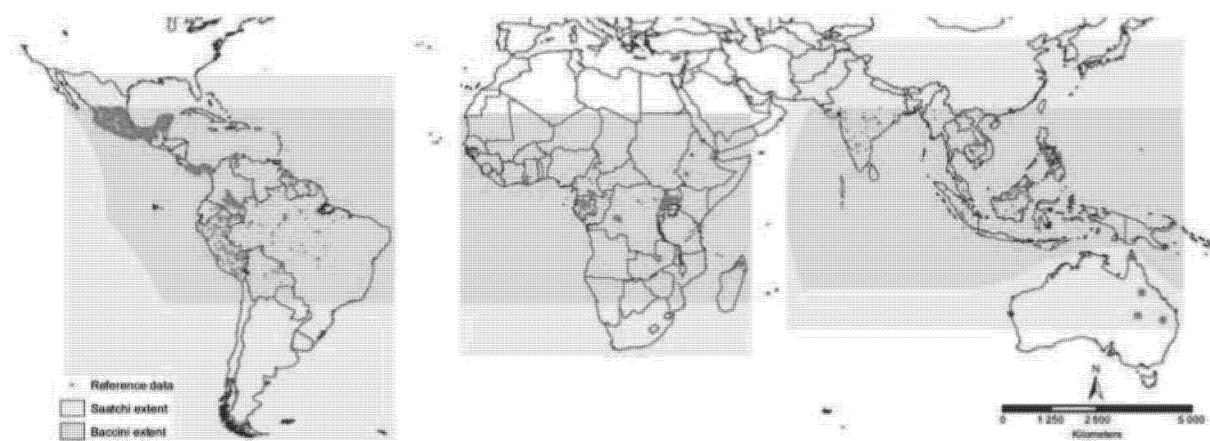


Figure 38 : Placettes de référence de biomasse aérienne et étendue des deux cartes pan tropicales précédentes. Extrait de Avitabile et al (2016).

Une cartographie nationale de la biomasse aérienne à Madagascar a été réalisée en 2015 à l'échelle de 250 m et à partir d'une compilation d'inventaires forestiers dans les forêts naturelles réalisés au cours des vingt dernières années (Vieilledent et al, 2016 ; 1771 placettes). Les auteurs montrent que la carte produite comporte des erreurs RMSE de 44 tC/ha (environ 40% d'erreur) et un biais de +30%. En comparaison sur Madagascar, les cartes globales montrent des erreurs de 64 tC/ha en moyenne (60%).

Les mêmes difficultés et ordre de grandeur d'incertitude sont observées pour la cartographie du carbone organique du sol. A l'échelle mondiale, les cartes à 1 km de résolution présentent des erreurs entre 23% et 51% (Hengl et al, 2014). A Madagascar, une récente étude a permis

de cartographier les stocks de carbone dans le sol à l'échelle nationale produite à partir de nombreux inventaires pédologiques issus d'études différentes centralisés et harmonisés dans une base de données nommée VALSOL (1196 placettes ; Ramifehiarivo et al, 2016; figure 39) et des variables environnementales spatialisées. La validation de cette cartographie montre des RMSE de 25,8 tC/ha (36,3 %). Cette étude de cartographie numérique des sols permet d'améliorer nettement une étude précédente réalisée par croisement d'unité sol et cartographie de la végétation à partir de données anciennes (Grinand et al, 2009 ; figure 39).

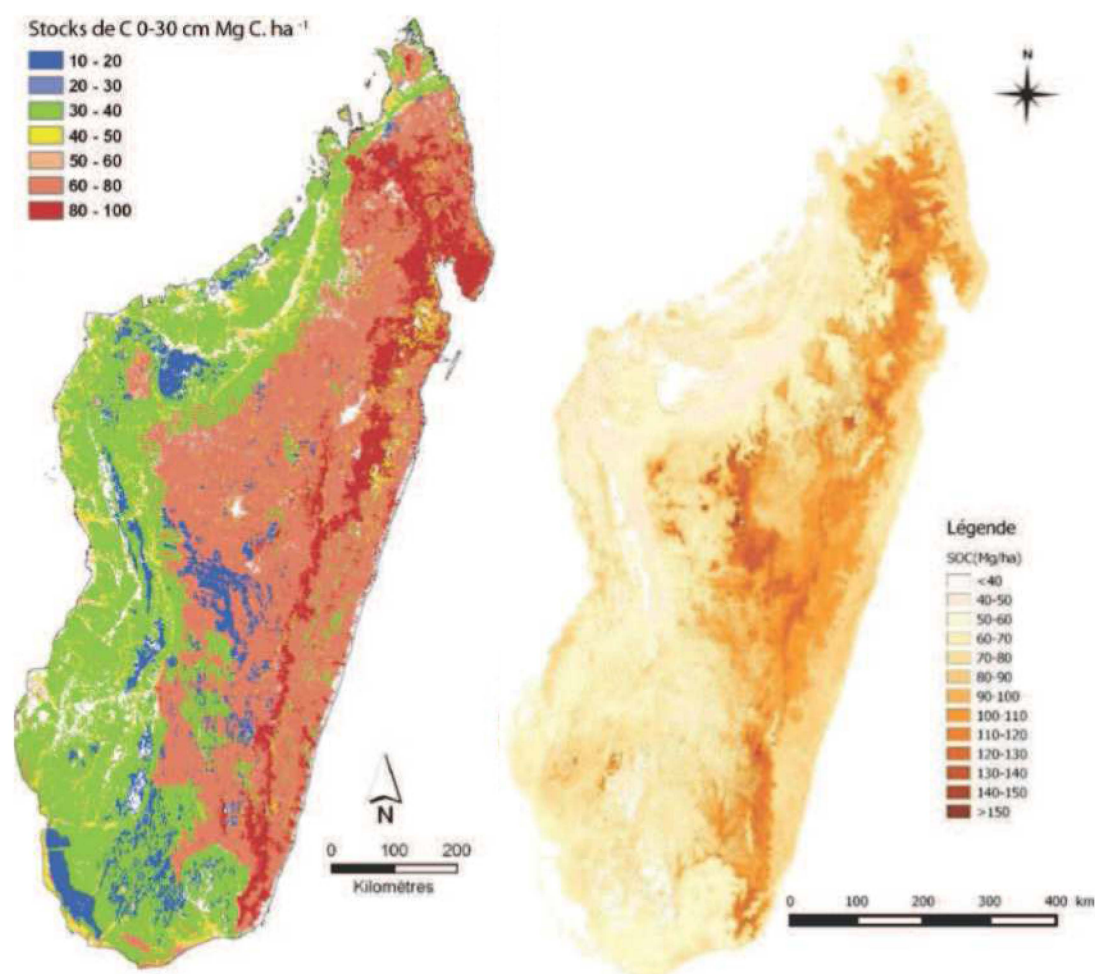


Figure 39 : Cartographie des stocks de carbone dans le sol sur 0-30 centimètres. A Gauche Grinand et al, 2009 et à droite, Ramifehiarivo et al, 2016.

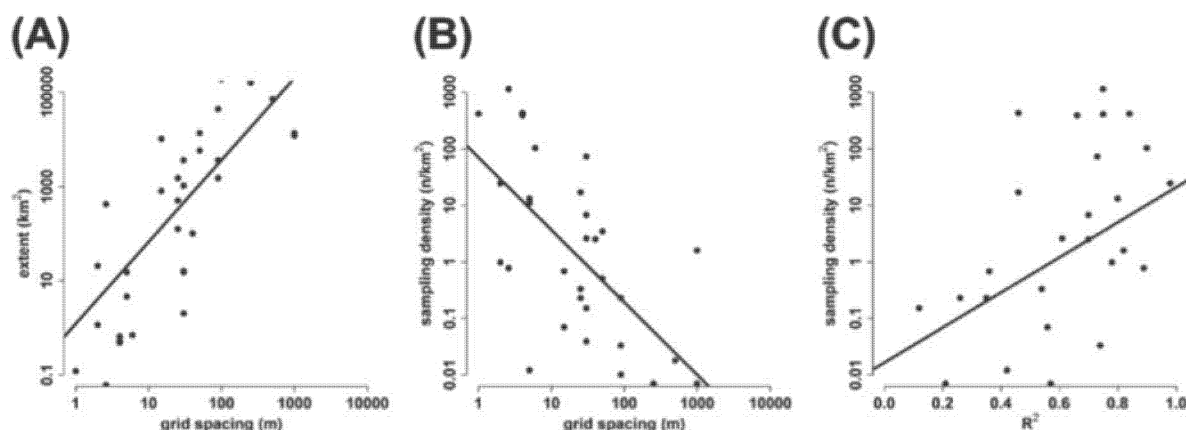


Figure 40 : Résultats des cartographies numérique du carbone du sol : (a) la relation entre la résolution (grid spacing) et l'étendue de l'étude, (b) la relation entre la densité d'échantillonnage et la résolution de la carte numérique, et (c) la relation entre la densité d'échantillonnage et le coefficient de détermination (R^2) pour les prédictions de carbone. Extrait de Minasny et al (2013).

La précision des cartographies dépend en grande partie du nombre de placettes utilisées dans la méthodologie, même si l'utilisation de données spatiales permet une extrapolation et *in fine* de réduit les coûts des estimations. Des techniques innovantes peuvent nous aider à démultiplier le nombre d'inventaires terrain que ce soit pour la biomasse ou le sol. C'est le cas de la technologie LiDAR qui permet d'estimer la hauteur des arbres à l'aide d'un émetteur et récepteur laser. Asner et al (2013) ont rapporté qu'il était possible d'obtenir des estimations avec 10% d'erreur à l'échelle d'un pixel de 100 m, par corrélation entre des cartes de hauteur des arbres dérivées du LiDAR et des inventaires terrain. Ces incertitudes sont de l'ordre de grandeur de celles enregistrées à la parcelle d'inventaire, liées aux mesures (hauteur, diamètre) et à l'équation allométrique utilisée, estimée entre 20% ou 30 %. (Chave et al, 2004). La technologie LiDAR est une solution intéressante, qui remplacera éventuellement les inventaires forestiers (Asner et al, 2013) mais son coût demeure élevé (~1 dollar par hectare). Les capteurs satellites LiDAR n'offrent pas pour l'instant de couverture exhaustive, mais seulement des données ponctuelles à emprise limitée au sol à l'instar des données GLAS du satellite ICESAT (l'impact du signal au sol correspond à un cercle de 70m de diamètre). D'autres solutions satellites existent pour nous aider à caractériser la distribution du carbone dans la biomasse. C'est le cas des données satellites Radar qui peuvent être utilisées pour estimer le stock des forêts peu denses ou très dégradées, mais dont le signal sature rapidement pour des forêts plus denses (Böttcher et al, 2009). Le satellite BIOMASS prévu pour 2020 devrait permettre de lever cette contrainte. Les solutions de fusion de données issus de capteurs différents semble être la voie à suivre (De Sy et al, 2012 ; Avitabile et al, 2011).

Concernant les sols, les voies d'amélioration demeurent clairement dans des alternatives aux mesures des propriétés sols en laboratoire. Les données d'analyses des sols coûtent cher (environ 50 euros par échantillon) et limitent de ce fait la quantité de données de calibration

ou validation pour alimenter les modèles spatiaux. Les techniques de spectrométrie dans l'infrarouge peuvent réduire considérablement le coût d'analyse (Viscarra Rossel et al, 2006) et offrent des moyens pour un système de suivi national de la qualité de sols (Grinand et al 2012 ; Clairotte et al, 2015). Le cas le plus avancé en Afrique aujourd'hui semble être le système de suivi des sols Ethiopiens (EthioSIS) utilisant les outils de spectroscopie en routine pour la production de cartographie d'indicateurs sols (Bellet, 2016). De nombreuses autres innovations sont possible (Lagacherie et al, 2008) : nouvelles covariables dont les données hyperspectrales satellitaires et utilisation des données d'inventaires existants, historiques.

Du point de vue du mécanisme REDD+, il semble que les seuils de 20 tC/ha ou 20% d'erreur à l'échelle du pixel soit une limite acceptable (Goetz et Dubayah, 2011) pour une incertitude à l'échelle du pixel même si aucune règle aujourd'hui n'a été déterminée. Ces seuils peuvent être considérés comme acceptables au niveau d'un pays (niveau 3) pour la quantification des stocks de carbone et émissions de CO₂ à un moment donné.

Néanmoins, en vue de la mise en place d'un système de suivi-évaluation des impacts environnementaux, les enjeux portent sur notre capacité à **détecter des changements de carbone**, avec ces mêmes exigences de précision. En d'autres termes, de passer à une cartographie « statique » de l'état et distributions de la ressource, à une cartographie dynamique ou semi-dynamique des prélèvements et restauration de la ressource.

2.2.2 Vers un suivi de la dégradation et régénération forestière

Dans le cadre de cette thèse, une première cartographie des stocks de carbone de la biomasse à l'échelle nationale été menée (Vieilledent et al, 2016 ; voir Annexe). Elle présente une carte développée grâce à la compilation de 1171 placettes d'inventaire forestier, provenant d'inventaires nationaux historiques (IEFN, 1996) et d'inventaires réalisés dans le cadre des quatre projets pilotes REDD+. La méthode de cartographie est similaire à celle proposée dans le chapitre 3, à savoir l'utilisation de l'algorithme Random Forest et des variables environnementales spatialisées. Alors que dans le chapitre 2 nous sommes intéressés aux changements passés des stocks de carbone dans le sol, cette étude sur la biomasse s'est intéressée à la prédiction future des stocks de carbone de la biomasse, selon les scénarios de changement climatique (figure 41). Elle a permis de mettre en évidence une potentielle réduction des stocks de carbone de 17% à l'horizon 2080 pour le scénario le plus défavorable (RCP 8.5, 4°C d'augmentation en 2100).

Suivant cette même logique et compte tenu des résultats du chapitre 3, nous pouvons imaginer combler le manque de connaissance sur les dynamiques de dégradation et régénération de la forêt. En effet, à partir du développement d'un modèle spatial du carbone aérien actuel, nous pouvons l'appliquer sur des données de végétation anciennes (archives d'images satellites

Landsat) et évaluer les changements de stock de carbone. Ces gains et pertes de carbone forestier nous indiqueraient directement les zones potentielles de dégradation et de régénération, et permettraient *in fine* d'améliorer le système de suivi des forêts (voir 2.1.3). Cette approche n'est pas complètement nouvelle et trouve ses origines dans l'exploitation de données de moyenne résolution de type SPOT-4 Vegetation (Mayaux et al, 2000) ou plus récemment du capteur MODIS (Gond et al, 2013). Ces données satellites sont caractérisées par des résolutions grossières (entre 250 m et 1 km) et des fréquences d'acquisitions élevées (journalier ou décadaire) ce qui permet des nombreuses observations « sans nuage » au cours de l'année. Elles ont été utilisées avec succès pour différencier les types de végétation en se basant sur leurs dynamiques phénologiques intra-annuelles en région d'Afrique Centrale (Gond et al, 2013). Au Brésil, les données MODIS ont été utilisées pour suivre la biomasse des grandes plantations d'Eucalyptus (Le Maire et al, 2011), laissant envisager un usage opérationnel pour les exploitants forestiers. Ce dernier exemple prouve que la technique est possible mais elle n'a pas aujourd'hui encore fait ses preuves pour le suivi de la dégradation forestière et la régénération naturelle.

Les difficultés résident dans i) la production des facteurs biophysiques, proxy de la biomasse, qui ne soient pas liés à des effets saisonniers, ii) sans couverture nuageuse et iii) avec des résolutions suffisamment fines. Les données MODIS à 250 ou 500 m de résolution sont trop grossières pour caractériser les activités de coupes sélectives, plantations d'arbres à l'échelle de la petite exploitation familiale ou des parcelles de culture abandonnées. L'utilisation des archives Landsat sur plus d'une vingtaine d'année permet de contourner cette limitation. Cependant les données Landsat sans nuage ne sont pas disponibles chaque année et acquises à différentes périodes de l'année. Le calcul de NDVI intégré sur une ou plusieurs années permettrait d'avoir une information plus robuste pour estimer les stocks de carbone dans le temps.

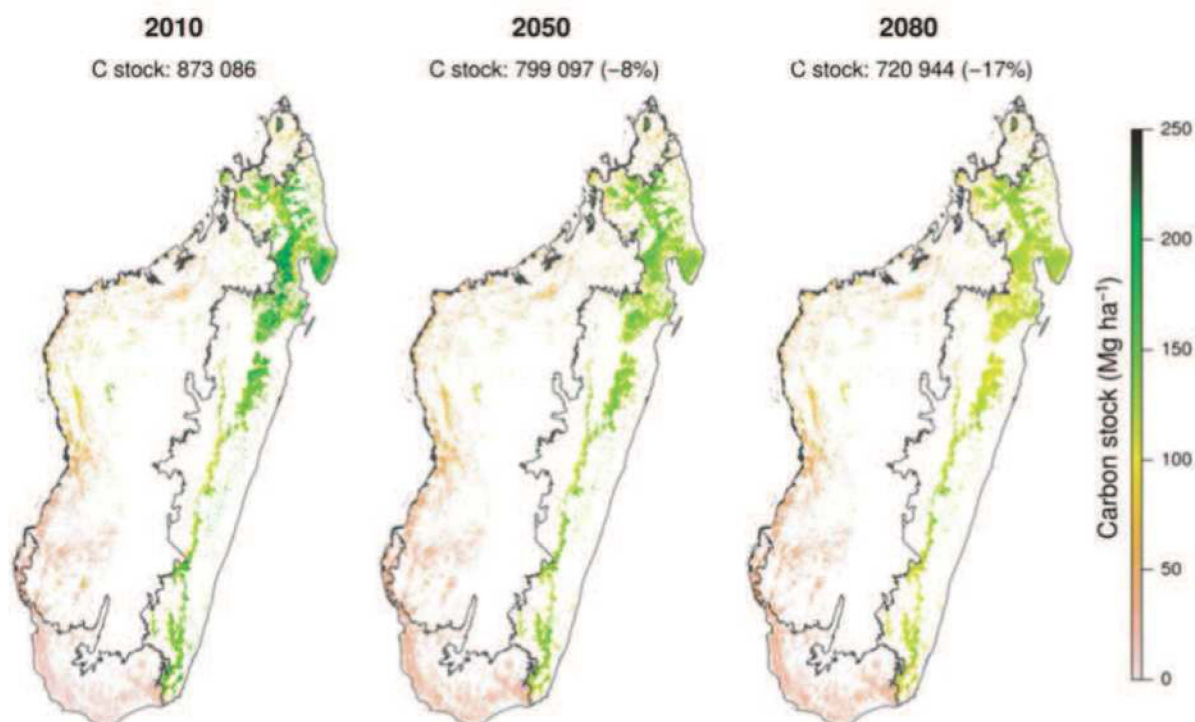


Figure 41 : Cartographie des stocks de carbone de Madagascar actuel et en fonction du changement climatique. Les cartographies en 2050 et 2080 utilisent des projections de l'IPCC CMIP5 des modèles globaux climatiques suivant le scénario RCP 8.5 et le model spatial de carbone calibré en 2010. Les stocks de carbone en Gg (1 Gg= 109g) sont indiqués, ainsi que la variation des stocks nationaux par rapport à l'année 2010. Extrait de Vieilledent et al, 2016.

2.2.3 Dynamique du carbone à l'échelle paysage

L'évolution récente de la REDD+ vers des approches « paysage » à l'instar du *Global Landscape Forum* organisé lors la COP21 (<http://www.landscapes.org/glf-2015/>). Cette initiative souligne la prise de conscience politique de la relation entre l'agriculture et la forêt et indique que les solutions doivent se trouver à des échelles locales, paysagères. Un des résultats présenté dans le chapitre 3 est la grande variabilité des stocks de carbone dans le sol (~dizaine de mètre) et leurs changements à l'échelle du paysage (entre -20 et +20% environ). L'analyse des facteurs de changements a été réalisée à posteriori, en s'intéressant essentiellement à la pratique de défriche brûlis. Pourtant, de nombreux autres facteurs sont à l'origine de ces changements et doivent être analysés si l'on veut faire des recommandations en termes de pratiques agricoles durables. La dynamique du carbone sol à l'échelle du paysage reste un sujet complexe, où interviennent à la fois des composantes biophysiques (ex. topographie, haies vives), de gestion des exploitations (ex. élevage, amendements organiques) et d'autres facteurs environnementaux (réserve en eau, érosion) (figure 42). Afin d'améliorer

notre étude et la rendre plus utile à des échelles de gestion des paysages, plusieurs axes de travail nous semble importants d'être développés.




Figure 42 : Composantes d'un agro-système à l'échelle d'un paysage. Extrait de Viaud et al, 2010.

- **Analyse des facteurs de changement de stocks de carbone**

Dans le deuxième chapitre nous avons présenté une méthode pour quantifier empiriquement les variations de stocks de carbone dans le sol. Les raisons de ces changements ont été évaluées *a posteriori* par des missions de terrain et le croisement avec d'autres sources de données (carte historique de la déforestation). Dans la continuité de cette approche, un sujet de recherche serait d'identifier plus généralement les déterminants anthropiques et biophysiques à l'origine des gains et pertes à partir de grands jeux de données empiriques produites. Le recours à des inventaires terrains (enquêtes sur les usages actuels et historiques) et la modélisation spatiale pourraient grandement aider à fournir des informations pertinentes sur les conditions de restauration des sols.

- **Étude du rôle de l'érosion sur le stockage de carbone.**

Le rôle de l'érosion est apparu au cours de la thèse, potentiellement comme un processus majeur dans le cycle du carbone. Il est aujourd'hui trop peu pris en compte, malgré des précédents programmes de recherche (Roose et al, 2006). Les mesures d'érosion sont souvent coûteuses, facilement biaisées car dépendantes des conditions locales (micro-topographie). Le déplacement de la couche superficielle est dommageable au niveau de la parcelle, mais ses effets sont limités lorsqu'on regarde l'ensemble du paysage. Il a été constaté au cours des missions de terrain, que nombre de rizières fertiles aujourd'hui existaient il y a plusieurs d'années et ont été enrichies par colluvionnement des particules fines et matière organique.

- **La cartographie de l'érosion et ressource en eau par des méthodes spatialisées**

L'érosion du sol est un indicateur tout aussi intégrateur que la matière organique du sol car il permet d'évaluer à la fois la perte en terre (tonnes par ha) qui traduit le décapement de la couche superficielle fertile du sol incluant la matière organique et le ruissellement/infiltration (en % de la précipitation) qui permet d'approcher les questions de recharge de l'aquifère superficiel, disponibilité de l'eau pour la plante et bilan hydrique en général. Cet indicateur a aussi l'avantage de réagir très rapidement (effet quantifiable au bout d'un an), au cours d'une année et en fonction du couvert végétal (Labrière et al, 2015).

- **Étude de l'apport des spectromètres miniatures de terrain**

Ces appareils sont en plein essor et comme toute nouvelle technologie, tendent à se condenser, être plus précis et moins onéreux. C'est le cas par exemple du MicroNIR JDSU qui a la taille d'une webcam. Il a été testé en parallèle de cette thèse en Haïti et Mozambique et semble offrir de belles perspectives (données non publiées). L'intérêt à moyen terme est de déployer des capacités de mesures directes (in-situ) pour le diagnostic de santé ou capacité des terres (carbone organique, argile, capacité d'échanges, azote, potassium). Ces outils demandent une phase de calibration et validation locale pour prendre en compte la diversité des types de sol.

2.3 Modéliser les changements d'usage des terres : trop complexe ?

Comme indiqué en introduction, les cadres méthodologiques de l'IPCC et GOFI GOLD n'apportent pas de recommandations pour la modélisation de la déforestation et des changements futurs, bien que le succès de la mise en œuvre de la REDD+ soit fortement dépendant de la méthode de construction des scénarios de référence (Huettnner et al, 2009). Deux raisons expliquent cela : d'une part les causes des changements sont complexes, avec des interactions entre échelles et des effets de rétroactions (*feedback*) difficiles à modéliser,

d'autre part les scénarios sur l'intensité de la déforestation constituent un sujet éminemment politique et économique, soumis à des chantages et querelles d'experts.

2.3.1 Intensité versus localisation

Certaines approches méthodologiques et notamment celles proposées dans le chapitre 3 séparent deux processus : la localisation des changements et leur quantité (intensité). Ce sont deux variables bien différentes qu'il est absolument nécessaire de différencier dans les modèles de changements d'usages des terres (Veldkamp and Lambin, 2001), car elles impliquent des données et méthode de validation différentes.

Concernant l'intensité, les méthodologies REDD+ actuelles s'appuient préférentiellement sur une approche simple de moyennes historiques (FCPF, 2013 ; VCS, 2014). Cela a l'avantage d'éviter d'introduire des incompréhensions sur le contenu des modèles. L'inconvénient est que ce taux historique dépend fortement de la période de référence considérée. L'intensité de déforestation moyenne du Brésil, par exemple, sur les 10 ou 20 dernières années est très différente. Des modèles économétriques modélisant uniquement l'intensité-notamment en prenant en compte des facteurs macro-économiques (prix des commodités sur les marchés internationaux, régulations politiques)- sont souvent critiqués pour leurs résultats fallacieux, mélangeant corrélation et causalité.

Les modèles spatiaux de la localisation ne sont pas épargnés par ces critiques lorsqu'il s'agit de déterminer les causes et facteurs des changements. Mais ils peuvent être plus facilement validés sur le terrain, c'est pourquoi ils sont encouragés par les standards REDD+. Ils sont aussi utiles quand ils se limitent à la localisation, c'est à dire à travers la production de cartes de risque de changement pour l'identification de *hot spots*. Ces cartes de risque scénarios peuvent également amener les décideurs à établir des règles (interdictions ou obligations dans certains périmètres ou à une certaine distance) dans des documents d'urbanisme ou planification territoriale au sens large (plans communaux ou régionaux de développement, plans de gestion d'une aire protégée). A ce titre, on peut citer les exemples concrets des cartes de risque d'inondation ou de glissement de terrain utilisées par les autorités locales et compagnies assurances.

2.3.2 Effet d'échelle versus effet de rétroactions

Une des difficultés de la modélisation des changements d'usage des terres est la prise en compte des effets d'échelles et de rétroactions ou « *feedback* ». Le premier implique une prise en compte des phénomènes locaux (ex. effet de l'altitude, distance à la lisière, proximité des rivières), régionaux (ex. distance aux marchés, infrastructures routières, gouvernance locale) et macro-économiques (ex. décisions politiques, prix des matières premières). Dans notre

étude nous avons pu intégrer les deux premières échelles à travers des données spatialisées mais les facteurs macro-économiques n'ont pas été intégrés. Ils peuvent pourtant s'avérer être une des premières causes de déforestation. C'est par exemple le cas du prix du maïs, expliquant la déforestation dans l'ouest de Madagascar. En effet, durant la décennie des années 1990, le prix avantageux pour le marché international et réunionnais a été tenu pour responsable des pertes considérables de forêts sèches (Casse et al, 2005 ; Gorenflo et al, 2010).

Les effets de « feedback » incluent différents types d'interactions qui résultent de dynamiques de changement qui s'amplifient (« feedback positif », comme par exemple la fonte des glaces du nord qui libère une grande quantité de méthane piégée dans les sols et accentue le changement climatique), s'atténuent (« feedback négatif », par exemple l'éloignement des villages de la lisière forestière à cause de la déforestation peut naturellement diminuer la déforestation et emmener les gens à trouver des alternatives comme planter des arbres ou valoriser les terres moins fertiles) ou provoquent des chocs abrupts lorsqu'un certain seuil est franchi (figure 43). Ces rétroactions ne peuvent pas être modélisés dans une approche statistique ou d'apprentissage automatique, car ils impliquent de décrire les interactions entre l'impact (changement d'usage des terres) et les forces motrices, dans les deux sens. Seuls les modèles basés sur les agents ou processus permettent d'intégrer ces rétroactions.




Figure 43 : Représentation schématisée des différents types de mécanismes de « feedback ». Extrait de Verburg et al, 2006.

2.3.3 Vers des modèles hybrides

D'après les paragraphes précédents on mesure à la fois l'intérêt de la modélisation des changements d'usage à des fins de compréhension des causes, d'appui aux politiques, et leur complexité. Il s'agit d'un domaine de recherche multi-disciplinaire et dans lequel il convient

de rester pragmatique, tourné vers les applications. A ce titre, on peut citer une étude qui a montré les attentes similaires et divergentes entre les décideurs et les experts concernant l'établissement de scénarios de référence REDD+ (Huetner et al, 2009 ; figure 44).

Afin d'améliorer les scénarios et à l'issu de cette recherche, il nous paraît important de combiner à la fois les modèles statistique ou d'apprentissage automatique avec des modèles basés sur les agents et processus dans une approche hybride. L'objectif étant de bénéficier des avantages des deux méthodes. Il s'agit de prolonger la méthode proposée dans le chapitre 3, inspirée des travaux au Vietnam (Castella et Verburg, 2007).

L'analyse empirique de l'importance des facteurs biophysiques et socioéconomiques et la production de cartes de risque de changement - à partir de données de télédétection traitées avec des algorithmes d'apprentissage automatique - permettent d'obtenir des résultats satisfaisants et généralisables à toutes les échelles. Elles peuvent être directement utilisées pour l'aide à la décision et facilement mises à jour avec des données additionnelles (ex. actualisation de l'historique de la déforestation, intégration d'un facteur sur la fertilité du sol, etc.) ou de meilleure qualité (ex. carte de la pente à 5 m de résolution au lieu de 90 m). Cette approche nous semble donc pertinente, même si elle ne couvre pas l'ensemble de facteurs de changement, notamment macro-économique et ne permet pas de construire des scénarios fins sur l'intensité des changements.

Afin de comprendre les causes et facteurs de changements tout en sensibilisant les acteurs, les approches participatives, à travers des jeux d'acteurs, nous semblent pertinentes. Ces approches sont par définition limitées dans l'espace (inventaire et enquête dans une sélection de villages) et partiellement représentatives de la population. Mais elles sont utiles pour i) enrichir ou confirmer notre compréhension des causes et facteurs élaborés dans l'analyse empirique précédente, ii) sensibiliser les acteurs aux problématiques à travers l'animation d'une discussion sur les dynamiques territoriales, et iii) co-construire des scénarios crédibles ou alternatifs, narratifs et quantitatifs, sur l'intensité des changements. Les résultats finaux, agrégés à des échelles administratives (communes ou régions) peuvent enfin être appliqués sur les cartes de risques (déforestation) et d'opportunité (régénération).

En conclusion, il n'existe pas de modèle ou d'approche juste et unique. Cependant la compréhension fine des facteurs des changements d'usage des terres et l'établissement de scénarios crédibles ou alternatifs permet, au-delà du carbone, de prendre conscience des pressions sur l'environnement et discuter des actions à mener entre toutes les parties prenantes du développement territorial.

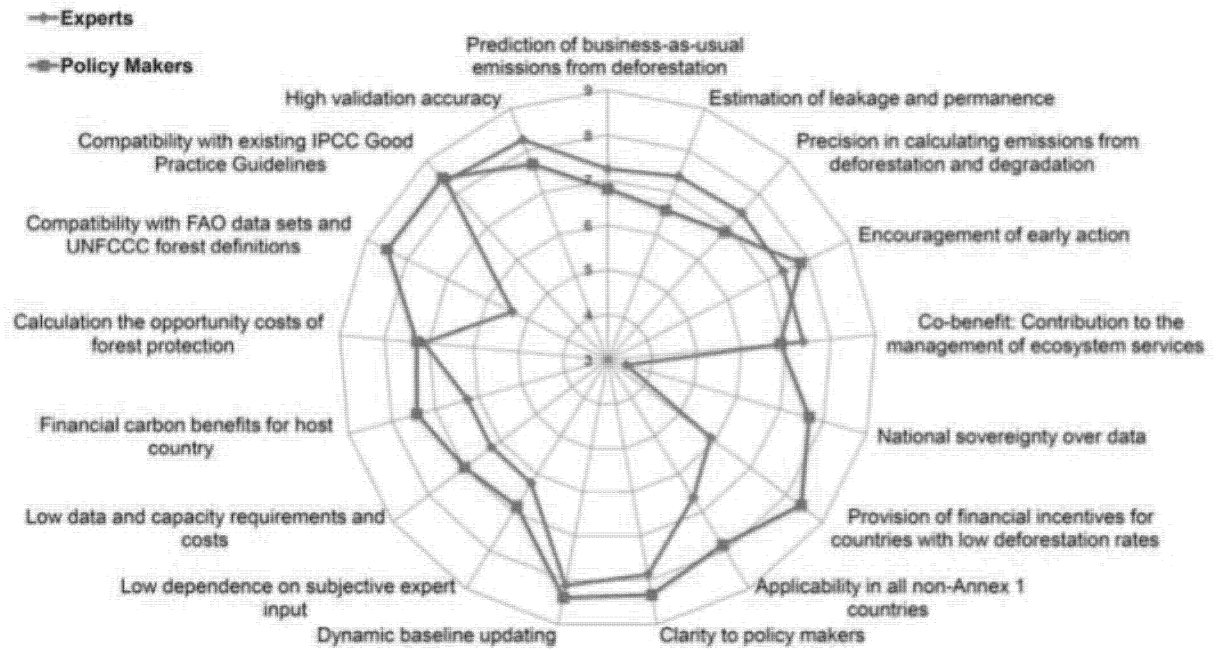


Figure 44 : Résultats de l'évaluation des critères d'importance pour le choix des méthodes d'établissement de scénario de référence REDD+ nationaux, selon les experts scientifiques (en bleu) et les décideurs (en rouge). Les valeurs à 0 indique une faible importance et les valeurs à 10 une forte importance. Extrait de Huettner et al, 2009.

2.4 Perspectives pour la mise en œuvre de la REDD+ à Madagascar

Cette thèse apporte différentes contributions à la stratégie REDD+ de Madagascar dans l'amélioration de nos connaissances sur les dynamiques des écosystèmes et leurs impacts climatiques, à des fins d'aides à la décision.

En terme de suivi de la déforestation, les avancées réalisées sont importantes : les dernières statistiques forestières datent de moins de 2 ans (ONE et al, 2015), la méthodologie est bien établie (Grinand et al, 2013 ; Rakotomalala et al, 2015) et maîtrisée par les acteurs locaux, notamment l'Office National de l'Environnement. On peut aujourd'hui actualiser régulièrement les chiffres nationaux de la déforestation, tous les 2 ou 3 ans. D'autres études et recherches doivent être menées afin d'intégrer les différents types de couvert forestier (plantations, forêts secondaires) et prendre en compte les dynamiques de dégradation/régénération dans un système national de suivi des forêts (voir 2.1.3).

En termes de mesure et suivi des stocks de carbone dans la biomasse et les sols, les travaux menés dans cette thèse ont fourni une première carte de biomasse à l'échelle nationale (Vieilledent et al, 2016), une version améliorée de la carte des stocks de carbone sol (Ramifehiarivo et al, 2016) et des facteurs d'émissions et séquestration du sol après déforestation (Grinand et al, 2017). Ces données peuvent être directement utilisées pour préciser les niveaux d'émissions de référence au niveau national. Au-delà de la REDD+, des recherches restent nécessaires pour réduire les incertitudes des estimations au niveau du pixel, notamment grâce à la mise en place de réseaux ou campagnes d'inventaire de terrain (forêt et sol) (voir 2.2.2 et 2.2.1).

En termes de modélisation des changements d'usage des terres, des nouveaux outils et cadre de travail ont été proposés afin d'analyser rapidement et quantitativement les facteurs locaux et régionaux des changements et co-construire des scénarios spatialisés (cf chapitre 4). Cette démarche peut être directement appliquée à l'échelle nationale et utilisée dans l'établissement des scénarios de référence. Bien qu'ils ne soient pas obligatoires au regard des standards REDD+ nationaux, une analyse robuste, compréhensible et exhaustive sur le territoire permettrait de mieux guider les politiques de gestion des terres, notamment dans la coordination des financements.

Enfin, ces avancées en termes de compatibilité carbone REDD+ et perspectives de travail s'inscrivent dans le cadre général de mise en place d'un système de suivi de l'état des forêts et des sols. Le succès d'un tel système devra passer par une volonté politique forte, un intérêt concret pour les populations rurales et une co-construction des outils et méthodes de suivi avec les institutions nationales.

3 Conclusion

Dans cette thèse un grand nombre de thématiques (foresterie, pédologie, REDD+) et disciplines techniques (télédétection, SIG, modélisation spatiale) ont été abordés. Cette pluridisciplinarité est indispensable pour toute évaluation de l'impact environnemental des activités humaines. La finalité de ce travail était de contribuer à une meilleure gestion des écosystèmes, par la fourniture d'information spatiales justes, précises, utilisables à différentes échelles, en vue et de faire évoluer les outils et méthodes utilisées dans les projets, programmes ou politiques REDD+.

Au cours de ces recherches nous avons développé et testé des méthodologies pour suivre les dynamiques de déforestation, évaluer les changements potentiels de stocks de carbone dans le sol et élaborer des scénarios basés sur une analyse des facteurs de changements d'usage des terres. Ces outils innovants ont été en partie publiés et utilisés dans d'autres régions ou à des échelles plus larges. Les connaissances acquises permettent de fournir des données d'activités et facteurs d'émission de niveau 3 à Madagascar, utiles pour réduire les incertitudes des niveaux d'émissions de référence nationaux ou infranationaux.

Ces travaux s'insèrent dans un programme de recherche-action plus large, en collaboration avec différentes équipes de recherche et acteurs de développement territorial. Dans le cadre du projet REDD+ PHCF, ces outils vont permettre d'améliorer les estimations du scénario de référence et l'implémentation du projet. À l'échelle nationale, le système de suivi des forêts est presque opérationnel, avec la réalisation d'une étude historique de la déforestation jusqu'en 2013, portée par les organismes et services techniques nationaux. Une plate-forme des parties prenantes REDD+ est en cours de constitution depuis le mois de juin 2016, elle devrait aboutir à la mise en place des outils de suivi de l'état des forêts. Enfin, des scénarios d'évolution de la déforestation élaborés dans le cadre d'un programme de recherche sur l'évolution de la biodiversité (BioSceneMada) seront prochainement diffusés auprès des gestionnaires de Parc afin de leur permettre d'améliorer ou actualiser leur plan de gestion.

La provision et profusion de données environnementales via les satellites d'observation de la Terre nous permet aujourd'hui de produire des indicateurs environnementaux à des fréquences élevées (annuelles), des résolutions fines (dizaine de mètres) et à des échelles mondiales. Les incertitudes sur les estimations de ces indicateurs (surface d'occupation du sol et de changements, stocks de carbone de la biomasse et du sol, projection des changements d'usages des terres futurs) restent importantes et des développements méthodologiques doivent encore être menés. La prise en compte des problématiques environnementales dans les pays en voie de développement doit passer par la co-construction d'outils et méthodes de suivi de l'état de la forêt et des sols, avec un fort soutien politique et répondant aux besoins des populations.

4 Références du chapitre 5

- Achard F, Eva HD, Stibig HJ, Mayaux P, Gallego J, Richards T, Malingreau JP. 2002. Determination of Deforestation Rates of the World's Humid Tropical Forests. *Science*, 09, 999-1002
- Allnutt TF, Asner G, Golden CD, Powell GVN. Mapping recent deforestation and forest disturbance in northeastern Madagascar. *Tropical Conservation Science* Vol.6 (1):1-15, 2013
- Asner, GP Mascaro J, Anderson C, Knapp DE, Martin RE, Bowdoin TK, van Breugel M, Davies S, Hall JS, Muller-Landau HC, Potvin C, Sousa W, Wright J, Bermingham E. 2013. High-fidelity national carbon mapping for resource management and REDD+. *Carbon Balance and Management*, 8:7. DOI: 10.1186/1750-0680-8-7
- Avitabile, V., Herold, M., Heuvelink, G. B. M., Lewis, S. L., Phillips, O. L., Asner, G. P., Armston, J., Ashton, P. S., Banin, L., Bayol, N., Berry, N. J., Boeckx, P., de Jong, B. H. J., DeVries, B., Girardin, C. A. J., Kearsley, E., Lindsell, J. A., Lopez-Gonzalez, G., Lucas, R., Malhi, Y., Morel, A., Mitchard, E. T. A., Nagy, L., Qie, L., Quinones, M. J., Ryan, C. M., Ferry, S. J. W., Sunderland, T., Laurin, G. V., Gatti, R. C., Valentini, R., Verbeeck, H., Wijaya, A. and Willcock, S. 2016. An integrated pan-tropical biomass map using multiple reference datasets. *Glob Change Biol*, 22: 1406–1420. doi:10.1111/gcb.13139
- Avitabile V, Herold M, Henry M, Schmulilius C. (2011) Mapping biomass with remote sensing: a comparison of methods for the case study of Uganda. *Carbon Balance Manag*, 6:7.
- Bellet T. 2016. The Role of DSM in Transforming Agriculture: The Case of Ethiopian Soil Information System (EthioSIS). 7 th Global DSM Workshop 2016, 27 June -1 July 2016, Aarhus, Denmark
- Bellot, F.-F.; Bertram, M.; Navratil, P.; Siegert, F.; Dotzauer, H. The High-Resolution Global Map of 21st-Century Forest Cover Change from the University of Maryland (“Hansen Map”). Is Hugely Overestimating Deforestation in Indonesia; FORCLIME Forests and Climate Change Programme: Jakarta, Indonesia, 2014
- Castella JC, Verbug PH. 2007. Combination of process-oriented and pattern-oriented models of land-use change in a mountain area of Vietnam. *Ecological modeling*, 202, 410-420

- Chave J, Chust G, Condit R, Aguilar S, Hernandez A, Lao S, Perez R. 2004. Error propagation and scaling for tropical forest biomass estimates. In Tropical forests and global atmospheric change. Edited by Malhi Y, Phillips O. London: Oxford University Press; 155–166
- De Sy V, Herold M, Achard F, Asner GP, Held A, Kellndorfer J, Verbesselt J. 2012. Synergies of multiple remote sensing data sources for REDD+ Monitoring. *Current Opinion in Environmental Sustainability*. 4:696–706. <http://dx.doi.org/10.1016/j.cosust.2012.09.013>
- Divay, 2014. Dossiers bois de rose à Madagascar, des nouveaux milliardaires. <https://blogs.mediapart.fr/philippe-divay/blog/091014/dossiers-bois-de-rose-madagascars-nouveaux-milliardaires>
- FCPF. 2013. FCPF Carbon Fund Methodological Framework. <https://www.forestcarbonpartnership.org/sites/fcp/files/2014/March/March/FCPF%20Carbon%20Fund%20Methodological%20Framework%20Final%20Dec%2020%202013.pdf>
- Gorenflo LJ, Corson C, Chomitz KM, Harper G, Honzák M, Özler B. 2010. Exploring the Association Between People and Deforestation in Madagascar. *Human Population*, 213, pp 197-221
- Gond V, Fayolle A, Pennec A, Cornu G, Mayaux P, Camberlin P, Doumenge C, Fauvet N, Gourlet-Fleury S. 2013 Vegetation structure and greenness in Central Africa from Modis multi-temporal data. *Phil Trans R Soc B* 368: 20120309. <http://dx.doi.org/10.1098/rstb.2012.0309>
- Grinand C, Rakotomalala F, Gond V, Vaudry R, Bernoux M, Vieilledent G. 2013. Estimating deforestation in tropical humid and dry forests in Madagascar from 2000 to 2010 using multi-date Landsat satellite images and the random forests classifier. *Remote Sensing of Environment* 139, 68–80.
- Grinand C, Barthès, B.G., Brunet, D., Kouakoua, E., Arrouays, D., Jolivet, C., Caria, G. Bernoux, M. 2012. Prediction of soil organic and inorganic carbon contents at national scale using mid infra red reflectance spectroscopy (MIRS). *European Journal of Soil Science*, 63, 2, 141–151. DOI: 10.1111/j.1365-2389.2012.01429.x
- Grinand C, Le Maire G, Vieilledent G, Razakamanarivo H, Razafimbelo T, Bernoux M. 2017. Estimating temporal changes in soil carbon stocks at ecoregional scale in

- Madagascar using remote-sensing. *Int. Journal of Applied Earth Observation and Geoinformation*, 54, 1–14. <http://dx.doi.org/10.1016/j.jag.2016.09.002>
- Hengl, T., Mendes de Jesus, J., Heuvelink, G. B.M., Ruiperez Gonzalez, M., Kilibarda, M. et al. SoilGrids250m: global gridded soil information based on Machine Learning. *PLOS One*, in review.
- Hengl T, de Jesus JM, MacMillan RA, Batjes NH, Heuvelink GBM, et al. (2014) SoilGrids1km — Global Soil Information Based on Automated Mapping. *PLoS ONE* 9(8): e105992. doi:10.1371/journal.pone.0105992
- Huettner M, Leemans R, Kok K, Ebeling J. 2009. A comparison of baseline methodologies for 'Reducing Emissions from Deforestation and Degradation. *Carbon Balance and Management*, 4,4. DOI: 10.1186/1750-0680-4-4
- Labrière N, Locatelli B, Laumonier Y, Freycon V, Bernoux (2015) Soil erosion in the humid tropics: A systematic quantitative review. *Agriculture, Ecosystems and Environment*, 203, 127–139.
- Le Maire, G, Marsden C, Nouvellon Y, Grinand C, Hakamada JS, Laclau JP (2011) MODIS NDVI time-series allow the monitoring of Eucalyptus plantation biomass. *Remote Sensing of Environment*, 115, 10, 2624-2625
- Mayaux P, Gond V., Bartholome E (2000) A near-real time forest-cover map of Madagascar derived from SPOT-4 VEGETATION data, *International Journal of Remote Sensing*, 21:16, 3139-3144, DOI:10.1080/01431160050145018
- MEFT, Ministry of the Environment, Forest and Tourism of Madagascar. 2009. Evolution de la couverture de forêts naturelles à Madagascar, 1990-2000-2005. Antananarivo, Madagascar, 132p.
- ONE, DGF, MNP, WCS & Etc Terra ; 2015. Changement de la couverture de forêts naturelles à Madagascar, 2005-2010-2013. Antananarivo. Madagascar. 21p
- ONE-DGF, HELVETAS-CIRAD. 2013. Atelier technique de partage des résultats intermédiaires de l'AT-REDD et de discussion des choix méthodologiques pour l'établissement d'une REL/RL et d'un système MRV pour la REDD. 26 septembre 2013. Antananarivo, Madagascar.
- Powell SL, Cohen WB, Healey SP, Kennedy RE, Moisen GG, Pierce KB, Ohmann JL. 2010. Quantification of live aboveground forest biomass dynamics with Landsat time-series and field inventory data: A comparison of empirical modeling approaches.

- Remote Sensing of Environment 114 (2010) 1053–1068.
doi:10.1016/j.rse.2009.12.018
- Ramifehiarivo N, Brossard M., Grinand C., Andriamananjara A., Razafimbelo T., Rasolohery A., Razafimahatratra Hery, Seyler F., Ranaivoson N, Rabenarivo M, Albrecht A, Razafindrabe F, Razakamanarivo H. 2016. Mapping soil organic carbon on a national scale: Towards an improved and updated map of Madagascar. *Geoderma*, 12, 2, <http://dx.doi.org/10.1016/j.geoder.2016.12.002>
- Rakotomala F.A , Rabenandrasana, J. C. , Andriambahiny, J. E. 4 , Rajaonson R. , Andriamalala, F. ,Burren, C. , Rakotoarijaona J.R. , Parany, L. , Vaudry, R. , , Rakotoniaina,S. , Grinand, C. 2015. Estimation de la déforestation des forêts humides à Madagascar entre 2005, 2010 et 2013. *Revue Française de Télédétection et Photogrammétrie*, 211-212, 11-23
- Randrianjafy H. 1999. Les plantations d'eucalyptus à Madagascar : Superficie, rôle et importance des massifs. Programme de partenariat CE-FAO
- Roose EJ, Lal R., Feller C., Barthès B., Stewart BA. Soil erosion and carbon dynamics. *Advances in Soil Science*, CRC Press Taylor and Francis, USA, 351 p.
- Sanchez PA, Ahamed S, Carré F, Hartemink AE, Hempel J, Huising J, Lagacherie P, McBratney AB, McKenzie NJ, Mendonça-Santos Mde L, Minasny B, Montanarella L, Okoth P, Palm CA, Sachs JD, Shepherd KD, Vågen TG, Vanlauwe B, Walsh MG, Winowiecki LA, Zhang GL. Digital soil map of the world. *Science*. 7;325(5941):680-1. doi: 10.1126/science.1175084
- VCS. 2014. Jurisdictional and Nested REDD+ Requirements, v3.2. <http://database.v-c-s.org/sites/vcs.benfredaconsulting.com/files/Jurisdictional%20and%20Nested%20REDD%2B%20Requirements,%20v3.2.pdf>
- Vieilledent, G., Gardi, O., Grinand, C., Burren, C., Andriamananjato, M., Camara, C., Gardner, C. J., Glass, L., Rasolohery, A., Rakoto Ratsimba, H., Gond, V. and Rakotoarijaona, J.-R. (2016), Bioclimatic envelope models predict a decrease in tropical forest carbon stocks with climate change in Madagascar. *J Ecol*, 104: 703–715. doi:10.1111/1365-2745.12548
- Viscarra Rossel RA. Walvoort DJJ, McBratney AB, Janick LJ, Skjemstad JO (2006) Visible, near infrared, mid infrared or combined diffuse reflectance spectroscopy for simultaneous assessment of various soil properties. *Geoderma*, 131, 59-75.
- Weatherley-Singha et Gupta, 2015

Liste des communications

Communications orales

Grinand C, Dessay N, Razafimbelo T , Razakamanarivo H , Albrecht A, Vaudry R, Tiberghien M, Rasamoelina M, and Bernoux M. High resolution regional soil carbon mapping in Madagascar : towards easy to update maps. European Geosciences Union General Assembly 2013. Vienne, Autriche, 8 avril 2013

Grinand C., Vieilledent, G., Le Maire, G., Razakamanarivo, H Razafimbelo, T. , Bernoux, M. Mapping temporal change of soil organic carbon: Impacts of deforestation in tropical humid and dry soil-landscape. Wageningen Soil Conference, Wageningen, Pays-Bas, 23-27 août 2015

Grinand C., Vieilledent G., H.Razafimbelo T. , Rakotoarijaona JR., Bernoux M. New tools and methodological framework to study spatial drivers of deforestation, degradation and regeneration and forecast possible futures in Madagascar. Scenarios and Models of Biodiversity and Ecosystem Services in Support of Decision Making (ScenNet Conference), Montpellier, France, 24-26 août 2016.

Liste des tableaux

TABLEAU 1 : MATRICE DES ACTIVITÉS REDD+, AFFORESTATION ET REFORESTATION (AR) ET GESTION DURABLE DES TERRES (GFT), ADAPTÉ D'APRÈS LES CATÉGORIES DU GIEC (IPCC, 2006). LES ACTIVITÉS EN ORANGE SONT ESTIMÉES PAR DES APPROCHES DE DIFFÉRENCE DE STOCKS ENTRE LA SITUATION INITIALE ET SITUATION D'ARRIVÉE (STOCK DIFFERENCE). LES ÉMISSIONS DES ACTIVITÉS EN VERT, SONT ESTIMÉES PAR DES APPROCHES DE « GAINS-PERTES ». * SELON LA DÉFINITION ADOPTÉE PAR LE PAYS.	20
TABLEAU 2. DÉFINITIONS DES SEUILS MINIMAUX POUR L'IDENTIFICATION DES FORÊTS SELON L'UNFCCC, LA FAO ET MADAGASCAR	23
TABLEAU 3 : LANDSAT IMAGE DATABASE USED IN THIS STUDY.	55
TABLEAU 4 : ERROR MATRIX AT PIXEL LEVEL WITH THE FCC MAP AND THE OBSERVED SAMPLE POINTS	67
TABLEAU 5 : FOREST SURFACE IN THOUSANDS OF HECTARES FOR EACH STUDY AREA AND ITS RELATED PROJECT SITE	69
TABLEAU 6 : DEFORESTATION ESTIMATES FOR EACH STUDY AREA AND ITS RELATED PROJECT SITE. * THE PERIOD IS APPROXIMATE IN THIS TABLE. IT IS VALID FOR ALL SITES EXCEPT COMATSA. FOR THE EXACT DATE OF THE PROCESSED IMAGE, SEE TABLE 1.	69
TABLEAU 7 : COMPARISON OF ANNUAL DEFORESTATION RATES FOR DIFFERENT PERIODS.	73
TABLEAU 8 : SOIL INVENTORY SUMMARY STATISTICS. N REPRESENT THE NUMBER OF SOIL SAMPLES FOR THE THREE SOIL VARIABLES AND NUMBER OF PLOTS FOR SOC 30 (SOIL ORGANIC CARBON STOCKS FOR THE TOP 30 CM SOIL LAYER) AND SOC 100 (SOIL ORGANIC CARBON STOCKS FOR THE TOP 100 CM SOIL LAYER). MIN. MINIMUM, MAX, MAXIMUM, S.D. STANDARD DEVIATION.	95
TABLEAU 9 : SPATIAL SOIL FACTOR DATABASE AND RESULTS OF CORRELATION WITH SOC STOCKS FOR 0-30 CM (SOC30) AND 0-100 CM (SOC100) SOIL LAYERS. * INDICATES THAT THE P-VALUE (PEARSON'S TEST) IS LESS THAN 0.01 FOR THE CORRELATION BETWEEN THE LANDSCAPE FACTOR AND THE SOC STOCK VALUE.	96
TABLEAU 10 : AVERAGED VALIDATION INDICES FOR THE 10 CROSS-VALIDATION RUNS. MINIMUM AND MAXIMUM VALUES RECORDED ARE IN BRACKETS.	100
TABLEAU 11 : ESTIMATED SOC STOCKS FOR FOREST AND CROP / SAVANNAH LAND COVER FOR THE 0-30 CM AND 0-100 CM SOIL LAYERS TAKEN FROM 1991 AND 2011 CARBON MAPS.	103
TABLEAU 12 : POTENTIAL CHANGES IN SOC STOCKS OVER THE STUDY AREA. "N" IS THE NUMBER OF OBSERVATIONS/PIXELS.	105
TABLEAU 13 : CHANGES IN SOC STOCKS FOR AREAS DEFOREST IN VARIOUS PERIODS. "N" IS THE NUMBER OF SOC CHANGE OBSERVATIONS (PIXELS). 5%Q AND 95%Q ARE THE 5% AND 95% QUANTILES. S.D. IS THE STANDARD DEVIATION.	107
TABLEAU 14 : ILLUSTRATION OF THE CHANGE MATRIX USED FOR VALIDATION AND DERIVED ACCURACY INDEXES.	136
TABLEAU 15 : HISTORICAL LAND CHANGE SUMMARY STATISTICS FOR 2000-2014 PERIOD. THESE STATISTICS WERE EXTRACTED USING A COMBINATION OF DATASETS FROM HANSEN ET AL (2013) AND GRINAND ET AL (2013).	138
TABLEAU 16 : RESULTS OF LINEAR LOGISTIC REGRESSION. SIGN. MEANS SIGNIFICATIVITY VALUES OF *** 0.001 ** 0.01 * 0.05. BOLD VALUES INDICATES FACTORS WITH Z VALUE ABOVE 10.	142
TABLEAU 17 : ACCURACY ASSESSMENT RESULTS	144
TABLEAU 18 : LAND CHANGE QUANTITY SCENARIOS FOR THE 2014-2034 PERIOD	145

Liste des figures

FIGURE 1 ILLUSTRATION SYNTHÉTIQUE (NON EXHAUSTIVE) DE LA PLACE DU CHANGEMENT CLIMATIQUE ET DU DÉVELOPPEMENT DURABLE DANS LES NÉGOCIATIONS INTERNATIONALES.....	12
FIGURE 2 : INTERFACE ENTRE SCIENCE ET POLITIQUE POUR LA GESTION DE L'ENVIRONNEMENT MONDIAL.....	13
FIGURE 3. LOCALISATION DES PROJETS REDD+ EN 2014. SIMONET ET AL, 2015	16
FIGURE 4: LOCALISATION DES PROJETS PILOTES REDD+ EN 2009. SOURCE : RPP MADAGASCAR, 2014.	18
FIGURE 5 : ILLUSTRATION DE L'ÉVALUATION DE L'IMPACT CLIMATIQUE À L'ÉCHELLE D'UN TERRITOIRE.	22
FIGURE 6 : ILLUSTRATION DES DIFFÉRENCES DE DÉFINITION ENTRE DEUX SYSTÈMES GLOBAUX DE SUIVI DES FORÊTS. SOURCE : WWW.LANDSCAPE.ORG	23
FIGURE 7. COMPARAISON DE DEUX CARTOGRAPHIES DE LA BIOMASSE AÉRIENNE (AGB) PAR SATELLITES DANS LA CEINTURE INTER-TROPICALE : a) ABG DE LA CARTE DE SAATCHI ET AL 2011. b) CARTE ABG DE BACCINI ET AL, 2012. c) LA DIFFÉRENCE ABSOLUE ENTRE A ET B. d) LE POURCENTAGE DE DIFFÉRENCE ENTRE LES DEUX CARTES. EXTRAIT DE MITCHARD ET AL, 2013. ..	25
FIGURE 8. ILLUSTRATION D'UNE MÉTHODE DE CARTOGRAPHIE INNOVANTE DE LA BIOMASSE AÉRIENNE, À PARTIR DE TECHNOLOGIE LIDAR AÉROPORTÉ. EXTRAIT DE ASNER ET AL, 2012. L'IMAGE DE GAUCHE REPRÉSENTE LE PLAN D'INVENTAIRE DES PLACETTES FORESTIÈRES (POINTS ROUGES) ET LE PLAN DE VOL DE L'AVION AVEC LE LIDAR EMBARQUÉ (RECTANGLE BLANC). L'IMAGE AU CENTRE ILLUSTRE LA CARTE PRODUITE APRÈS TRAITEMENT DES DONNÉES LIDAR (HAUTEUR MOYENNE DES ARBRES) À UNE RÉOLUTION MÉTRIQUE. L'IMAGE À DROITE EST LA CARTE RÉGIONALE DE BIOMASSE OBTENUE APRÈS EXTRAPOLATION SUR LA BASE DE FACTEURS ENVIRONNEMENTAUX SPATIALISÉS (INDICE DE VÉGÉTATION ET ALTITUDE).	26
FIGURE 9: VINGT CAUSES DE LA DÉFORESTATION LES PLUS ÉTUDIÉES, ORGANISÉE PAR SENS ET SIGNIFICATIVITÉ À PARTIR D'ÉTUDES DE RÉGRESSION MULTIVARIÉES. EXTRAIT DE FERRETTI GALLON ET BUSH (2014). LES CAUSES EN LETTRES CAPITALES INDIQUENT LES CAUSES DONT L'EFFET (POSITIF OU NÉGATIF) EST SIGNIFICATIF (TEST-T À 95% D'INTERVALLE DE CONFIANCE).	28
FIGURE 10: PROJECTION DE LA DÉFORESTATION ET DES ÉMISSIONS DE CARBONE ASSOCIÉE JUSQU'EN 2013 SUR LA RÉGION D'ANDAPA, NORD DE MADAGASCAR. EN ORANGE LA DÉFORESTATION POUR LA PÉRIODE 2010-2020 ET EN ROUGE POUR LA PÉRIODE 2020-2030. EXTRAIT DE VIELLEDENT ET AL, 2012.	30
FIGURE 11: ILLUSTRATION DE L'ORGANISATION DES THÉMATIQUES DE RECHERCHE ABORDÉES DANS CETTE THÈSE	32
FIGURE 12: CARTE DE LOCALISATION DES DIFFÉRENTES ZONES D'ÉTUDE EN FONCTION DES CHAPITRES.	33
FIGURE 13 : FLOW DIAGRAM OF THE PROCESSING STEPS. FCC STANDS FOR FOREST COVER CHANGE.	53
FIGURE 14: LOCATION OF THE STUDY AREAS AND PROJECT SITES IN MADAGASCAR. BACKGROUND SATELLITE IMAGES ARE LANDSAT 5 FROM CIRCA 2005 IN A FALSE COLOUR COMPOSITE DISPLAY, RGB=542. THE SOURCE OF THE ECO-REGION MAP IS THE GLOBAL 200 WORLD WIDE FUND PROJECT (HTTP://EN.WIKIPEDIA.ORG/WIKI/GLOBAL_200).	54
FIGURE 15 : STABLE LAND COVER AND EXAMPLES OF VISUAL INTERPRETATION OF LAND COVER CHANGE USING QGIS, QUICKBIRD/GOOGLE EARTH IMAGES AND LANDSAT IMAGES. FROM TOP LEFT TO BOTTOM RIGHT: CLUSTER OF TRAINING PLOTS OVERLAYING QUICKBIRD IMAGES FROM GOOGLE EARTH (22/05/2007) AND LANDSAT TM FALSE COLOUR COMPOSITE RGB=4,5,1 ACQUIRED AT DATES 29/04/2001, 9/12/2005 AND 17/11/2010. INDIVIDUAL OBSERVATIONS FOR EACH DATE AND FINAL FOREST COVER CHANGE CLASS FOR THE SEVEN TRAINING PLOT ARE PRESENTED IN THE TABLE OF ATTRIBUTES BELOW THE IMAGES.	57
FIGURE 16 : ILLUSTRATION OF POST-PROCESSING STEPS: 1) MINIMUM MAPPING UNIT FILTERING OF 0.36 HA USING A 3x3 MOVING WINDOW THAT RETAINS ONLY 2x2 DEFORESTATION PATCHES AND APPLIES A MAJORITY VOTE FOR OTHER CATEGORIES (FIRST TO SECOND PANEL) AND 2) CLOUD AND SHADOW REMOVAL USING THE 2005 FOREST MAP (SECOND TO THIRD PANEL). GREEN REPRESENTS THE EXTENT OF THE FOREST, LIGHT YELLOW THE NON FOREST, ORANGE DEFORESTATION IN THE 2000-2005 INTERVAL, AND RED DEFORESTATION IN THE 2005-2010 INTERVAL. WHITE PIXELS REPRESENT CLOUDS, AND BLACK PIXELS SHADOWS.	60
FIGURE 17 : ILLUSTRATION OF THE POINT SAMPLING DESIGN WITH THE TWO STRATA USED FOR THE ASSESSMENT OF ACCURACY. STRATUM 1 CORRESPONDS TO ONE SAMPLE EVERY TWO KILOMETERS OVER THE ENTIRE STUDY AREA (AREA IN GREY AND BLUE DOTS) AND STRATUM 2 CORRESPONDS TO ONE SAMPLE EVERY FIVE HUNDRED METERS IN PREVIOUSLY LOCATED HOT SPOT AREAS (AREA IN YELLOW AND YELLOW DOTS).	63
FIGURE 18 : RANDOM FOREST CALIBRATION SUMMARY STATISTICS. THE FIRST COLUMN CORRESPONDS TO THE NUMBER OF OVERALL TRAINING PLOTS, THE SECOND COLUMN TO THE SAMPLING INTENSITY TEST AND THE THIRD COLUMN TO THE RELATIVE IMPORTANCE OF THE VARIABLES.	66
FIGURE 19 : SATELLITE IMAGES AND FINAL MAP OF FOREST COVER CHANGE FOR THE PERIODS 2000-2005-2010. a) QUICKBIRD/GOOGLE EARTH ACQUIRED ON MARCH 17, 2011. b) LANDSAT FALSE COLOUR COMPOSITE RGB=TM5-3-2	

ACQUIRED ON NOVEMBER 17, 2010. c) FOREST COVER CHANGE 2000-2010 MAP, GREEN REPRESENTS THE EXTENT OF THE FOREST, LIGHT YELLOW REPRESENTS NON-FOREST, ORANGE REPRESENTS DEFORESTATION BETWEEN 2000 AND 2005, AND RED REPRESENTS DEFORESTATION BETWEEN 2005 AND 2010. THE FCC MAP IS AVAILABLE IN KMZ FORMAT IN SUPPLEMENTARY MATERIAL.	66
FIGURE 20 :ACCURACY ASSESSMENT. A) NUMBER OF SAMPLES OBSERVED IN EACH CATEGORY, B) PER-PIXEL ACCURACY, AND C) RELATIVE DIFFERENCE (AREA AND DEFORESTATION RATE) BETWEEN POINT SAMPLING AND FCC APPROACH. DEFOR P1: DEFORESTATION IN PERIOD 1 (2000-2005), DEFOR P2: DEFORESTATION IN PERIOD 2 (2005-2010).	68
FIGURE 21 :LOCATION OF THE STUDY AND REFERENCE AREAS WITH BOTH DRY AND HUMID CLIMATES. THE LANDSAT IMAGE ON THE RIGHT WAS ACQUIRED ON JULY 5 2011. THE ECOREGION MAP (TOP LEFT) WAS EXTRACTED FROM THE GLOBAL 200 WORLD WIDE FUND PROJECT (HTTP://EN.WIKIPEDIA.ORG/WIKI/GLOBAL_200). THE BOUNDARY BETWEEN THE DRY AND HUMID REGIONS (YELLOW LINE ON MAP ON RIGHT) WAS EXTRACTED FROM (IEFN, 1997). THE ELEVATION MAP (BOTTOM LEFT) WAS EXTRACTED FROM THE ASTER GLOBAL DIGITAL ELEVATION MAP (2011).	93
FIGURE 22 :PREDICTED VS MEASURED PLOT FOR CALIBRATION AND VALIDATION DATASETS FOR SOC 0-30CM SOIL LAYER (A) AND 0-100 CM (B) SOIL LAYER AND AVERAGE RELATIVE IMPORTANCE OF VARIABLES FOR BOTH SPATIAL MODELS (C AND D). VARIABLE NAMES AND DESCRIPTION ARE GIVEN IN TABLE 2. THE ACCURACY MEASUREMENTS (R2, RMSE, BIAS, RPD, CV) ARE THOSE CALCULATED FOR THE VALIDATION DATASET (SEE ALSO TABLE 3).	101
FIGURE 23 :SOC (0-100 CM) MAPS PRODUCED FOR 1991 AND 2011 FOR THE ENTIRE STUDY AREA AND AN ENLARGEMENT OF A MOUNTAINOUS AND FORESTED LANDSCAPE (A) ASSOCIATED WITH SHIFTING CULTIVATION PLOTS (B) AND UNDULATING GRASSLAND VALLEY (C).....	103
FIGURE 24 :POTENTIAL SOC CHANGE MAP 1991-2011 FOR THE 0-30 CM AND 0-100 CM SOIL LAYERS AND A 3D LANDSCAPE VIEW. THE AREA IN WHITE REPRESENTS NO SIGNIFICANT CHANGE AND NO DATA IS AVAILABLE FOR THE AREAS IN BLACK. THE BLUE POLYLINE ENCLOSES THE AREAS SUBJECT TO DEFORESTATION BETWEEN 1990 AND 2010 (MEFT, 2009; GRINAND ET AL, 2013).	105
FIGURE 25 :POTENTIAL CHANGES IN SOC STOCKS ESTIMATED AS A FUNCTION OF THE INITIAL STOCKS OVER THE STUDY AREA. EACH GRAPH WERE CREATED USING 100 000 OBSERVATIONS/PIXELS RANDOMLY SELECTED. COLORS INDICATE DENSITY OF OBSERVATIONS/PIXELS (FROM WHITE-BLUE TO GREEN, RED).	106
FIGURE 26 : SOC CHANGE (0-30 CM – HUMID REGION) BETWEEN 1991 AND 2011 FOR VARIOUS DEFORESTATION PERIODS. EACH GRAPH WERE CREATED USING 15 000 OBSERVATIONS/PIXELS RANDOMLY SELECTED. COLORS INDICATE DENSITY OF OBSERVATIONS/PIXELS (FROM WHITE-BLUE TO GREEN, RED).	107
FIGURE 27 : ANNUAL DEFORESTATION IN HECTARES FOR THE HISTORICAL PERIOD. VALUES WERE EXTRACTED FROM FOREST LOSS YEAR DATA PRODUCT (HANSEN ET AL, 2013) AND INTACT FOREST EXTENT (GRINAND ET AL, 2013), AND SMOOTHED WITH A MOVING WINDOW OF THREE YEARS.	138
FIGURE 28 : DRIVER ANALYSIS OF DEFORESTATION. THE DASHED LINE REPRESENT THE 50% PROBABILITY, VALUES ABOVE INDICATES HIGH RISK OF DEFORESTATION, VALUES BELOW INDICATES LOW RISK.	140
FIGURE 29 :DRIVER ANALYSIS OF LAND DEGRADATION. THE DASHED LINE REPRESENT THE 50% PROBABILITY, VALUES ABOVE INDICATES HIGH RISK OF DEFORESTATION, VALUES BELOW INDICATES LOW RISK.	140
FIGURE 30 :DRIVER ANALYSIS OF REGENERATION. THE DASHED LINE REPRESENT THE 50% PROBABILITY, VALUES ABOVE INDICATES HIGH RISK OF DEFORESTATION, VALUES BELOW INDICATES LOW RISK.	141
FIGURE 31 : ILLUSTRATION OF THE TWO MAIN PREDICTORS (ELEVATION AND DISTANCE TO THE FOREST EDGE) EFFECTS REGARDING DEFORESTATION, LAND DEGRADATION AND LAND REGENERATION.	143
FIGURE 32 : ILLUSTRATION OF THE THREE LAND TRANSITIONS MAPS	144
FIGURE 33 :LAND CHANGE MAPS FOR 2014-2034 PERIOD ACCORDING TO THE THREE SCENARIOS	145
FIGURE 34 : 3D VIEW OF LAND USE CHANGE PROJECTION FOR THE THREE SCENARIOS.....	146
FIGURE 35 : LAND CHANGE ALLOCATION RESULTS ACCORDING TO THE THREE SCENARIOS FOR DIFFERENT EXTENTS: THE ANDOHELA NATIONAL PARKS, THE MIDONGY NATIONAL PARKS AND OUTSIDE THOSE TWO PERIMETERS.	148
FIGURE 36 : ILLUSTRATION DE LA « CARTE DE HANSEN ». CARTE MONDIALE DES CHANGEMENTS DE COUVERTURE ARBORÉE POUR LA PÉRIODE 2000-2012. EXTRAIT DE HANSEN ET AL, 2013.....	167
FIGURE 37 : CARTE DE L'HISTORIQUE DE LA DÉFORESTATION DANS L'ÉCORÉGION HUMIDE DE L'EST DE MADAGASCAR AVEC UN ZOOM SUR UNE ZONE À FORTE INTENSITÉ (HOT SPOT) DE DÉFORESTATION. EXTRAIT DE RAKOTOMALALA ET AL, 2015	171
FIGURE 38 : PLACETTES DE RÉFÉRENCE DE BIOMASSE AÉRIENNE ET ÉTENDUE DES DEUX CARTES PAN TROPICALES PRÉCÉDENTES. EXTRAIT DE AVITABILE ET AL (2016).....	172
FIGURE 39 : CARTOGRAPHIE DES STOCKS DE CARBONE DANS LE SOL SUR 0-30 CENTIMÈTRES. A GAUCHE GRINAND ET AL, 2009 ET À DROITE, RAMIFEHIARIVO ET AL, 2016.	173
FIGURE 40 : RÉSULTATS DES CARTOGRAPHIES NUMÉRIQUE DU CARBONE DU SOL : (A) LA RELATION ENTRE LA RÉOLUTION (GRID SPACING) ET L'ÉTENDUE DE L'ÉTUDE, (B) LA RELATION ENTRE LA DENSITÉ D'ÉCHANTILLONNAGE ET LA RÉOLUTION DE LA CARTE NUMÉRIQUE, ET (C) LA RELATION ENTRE LA DENSITÉ D'ÉCHANTILLONNAGE ET LE COEFFICIENT DE DÉTERMINATION (R ²) POUR LES PRÉDICTIONS DE CARBONE. EXTRAIT DE MINASNY ET AL (2013).	174

FIGURE 41 : CARTOGRAPHIE DES STOCKS DE CARBONE DE MADAGASCAR ACTUEL ET EN FONCTION DU CHANGEMENT CLIMATIQUE. LES CARTOGRAPHIES EN 2050 ET 2080 UTILISENT DES PROJECTIONS DE L'IPCC CMIP5 DES MODÈLES GLOBAUX CLIMATIQUES SUIVANT LE SCÉNARIO RCP 8.5 ET LE MODEL SPATIAL DE CARBONE CALIBRÉ EN 2010. LES STOCKS DE CARBONE EN Gg (1 Gg= 109G) SONT INDICUÉS, AINSI QUE LA VARIATION DES STOCKS NATIONAUX PAR RAPPORT À L'ANNÉE 2010. EXTRAIT DE VIEILLEDENT ET AL, 2016.	177
FIGURE 42 : COMPOSANTES D'UN AGRO-SYSTÈME À L'ÉCHELLE D'UN PAYSAGE. EXTRAIT DE VIAUD ET AL, 2010.	178
FIGURE 43 : REPRÉSENTATION SCHÉMATIQUE DES DIFFÉRENTS TYPES DE MÉCANISMES DE « FEEDBACK ». EXTRAIT DE VERBURG ET AL, 2006.	181
FIGURE 44 : RÉSULTATS DE L'ÉVALUATION DES CRITÈRES D'IMPORTANCE POUR LE CHOIX DES MÉTHODES D'ÉTABLISSEMENT DE SCÉNARIO DE RÉFÉRENCE REDD+ NATIONAUX, SELON LES EXPERTS SCIENTIFIQUES (EN BLEU) ET LES DÉCIDEURS (EN ROUGE). LES VALEURS À 0 INDIQUE UNE FAIBLE IMPORTANCE ET LES VALEURS À 10 UNE FORTE IMPORTANCE. EXTRAIT DE HUETTNER ET AL, 2009.	183

Annexes

Annexe 1: Rakotomala F.A , Rabenandrasana, J. C. , Andriambahiny, J. E. 4 , Rajaonson R. , Andriamalala, F. ,Burren, C. , Rakotoarijaona J.R. , Parany, L. , Vaudry, R. , , Rakotoniaina,S. , Grinand, C. 2015. Estimation de la déforestation des forêts humides à Madagascar entre 2005, 2010 et 2013. Revue Française de Télédétection et Photogrammétrie, 211-212, 11-23.

Annexe 2: Vieilledent G, Gardi O, Grinand C, Burren C, Andriamanjato M, Camara C, Gardner CJ, Glass L, Rasolohery A, Ratsimba H, Gond V, Rakotoarijaona J. 2016. Bioclimatic envelope models predict a decrease in tropical forest carbon stocks with climate change in Madagascar. Journal of Ecology, 104, 703-715.

Annexe 3: Clairotte M, Grinand C. Kouakoua E, Thebault A, Saby N, Bernoux M, Barthès B. 2016. National calibration of soil organic carbon concentration using diffuse infrared reflectance spectroscopy. 276, 41-52, <http://doi.org/10.1016/j.geoderma.2016.04.021>

Annexe 4 : Ramifehiarivo N, Brossard M., Grinand C., Andriamananjara A., Razafimbelo T., Rasolohery A., Razafimahatratra Hery, Seyler F., Ranaivoson N, Rabenarivo M, Albrecht A, Razafindrabe F, Razakamanarivo H. 2016. Mapping soil organic carbon on a national scale: Towards an improved and updated map of Madagascar. Geoderma, 12, 2, <http://dx.doi.org/10.1016/j.geodrs.2016.12.002>

Estimation de la déforestation des forêts humides à Madagascar utilisant une classification multidate d'images Landsat entre 2005, 2010 et 2013

Rakotomala F.A.^{1,5}, Rabenandrasana, J. C.², Andriambahiny, J. E.⁴, Rajaonson, R.², Andriamalala, F.⁴, Burren, C.², Rakotoarijaona, J.R.³, Parany, B.L.E.⁴, Vaudry, R.¹, Rakotoniaina, S.⁵, Ranaivosoa, R.³, Rahagalala, P.³, Randrianary, T.¹, Grinand, C.⁶,

1: Etc Terra, Lot VE 26 L, Ambanidia, 101 Antananarivo, Madagascar

2: WCS, Wildlife Conservation Society, Villa Ifanomezana, Face II A78 D Soavimbahoaka, BP 8500 Antananarivo, Madagascar

3 : ONE, Office National de l'Environnement, Rue Rainilaiarivony, BP 822, Antananarivo, Madagascar

4 : MNP, Madagascar National Parks, Madagascar, BP 1424, 103 Antananarivo, Madagascar

5 : IOGA, Instituts et Observatoires de Géophysiques d'Antananarivo, Université d'Antananarivo, Faculté des sciences, Madagascar

6 : Etc Terra, 127 rue d'Avron, Paris - France

Résumé

La spatialisation de la dynamique forestière est essentielle à l'estimation des niveaux d'émissions de gaz à effet de serre dans les forêts affectés par la déforestation. L'objectif de cette étude était d'estimer le niveau de la déforestation et de mieux comprendre la dynamique des forêts humides de l'Est de Madagascar entre 2005-2010-2013. Une approche de classification supervisée d'images Landsat multitudes utilisant l'algorithme *Random Forest* a été utilisée. Une carte complète de l'évolution du couvert forestier à 30 mètres de résolution spatiale a été produite sur 20,5 millions d'hectares. Le résultat a été validé par photo-interprétation de près de 11 000 points à partir d'un échantillonnage de points régulier et sur la base d'images satellites SPOT et Landsat pour la période 2010-2013. La précision globale de la carte de la déforestation ainsi produite a été évaluée à environ 90%. La superficie des forêts humides de l'Est de Madagascar a ainsi été estimée à 4,5 millions d'hectares en 2005, 4,4 millions d'hectares en 2010 et 4,3 millions d'hectares en 2013. Le taux de déforestation annuel a augmenté de 0,5% à 0,9% entre les deux périodes étudiées. Cette étude permet d'envisager le développement d'une démarche de suivi de l'état des forêts fiable, à moindre coût et reproductible dans le temps.

Mots-clés : Télédétection, images Landsat, *RandomForest*, déforestation, dynamique forestière.

Abstract

Monitoring forest state is required to estimate the levels of greenhouse gases emissions from deforestation. The objective of this study was to estimate deforestation trends for 2005-2010 and 2010-2013 periods in the eastern rainforests ecoregion of Madagascar. A supervised classification approach of multi-date Landsat images using the Random Forest algorithm was used. A complete 30 m map of the forest cover change was produced on 20.5 million hectares. The result was validated by photo interpretation of nearly 11 000 points from a regular sampling grid on the basis of SPOT and Landsat satellite images acquired in 2010-2013. The overall mapping accuracy was estimated to be about 90%. The area of Madagascar rainforests has been estimated at 4.5 million hectares in 2005, 4.4 million hectares in 2010 and 4.3 million hectares in 2013. The annual rate of deforestation has increased from 0.5% to 0.9 % between the two periods. This study could be considered as a reliable cost-effective and reproducible approach for monitoring forests in Madagascar.

Keywords: Remote sensing, Landsat images, *Random Forest*, deforestation, forest cover change.

1. Introduction

La réduction du couvert forestier n'est pas un phénomène récent et est associée depuis longtemps aux activités humaines (Williams *et al.*, 2002). À partir d'observations satellitaires, Achard *et al.*, (2002) ont montré que les forêts couvraient 4 milliards d'hectares soit près de 30% de la surface émergée du globe en 2000. Plus récemment, Hansen *et al.*, (2013) ont estimé que le couvert forestier mondial avait subi une perte de 2,5 millions de kilomètres carrés durant la

période 2000 à 2012, soit un rythme de 2 100 kilomètres carrés chaque année, principalement localisés en climat tropical. Par ailleurs, les écosystèmes forestiers constituent un réservoir terrestre important de carbone. La conversion de terres forestières en terres agricoles (déforestation) est responsable de 17% des émissions annuelles de Gaz à Effet de Serre (GES) d'origine anthropique (GIEC, 2007). Afin d'apporter des solutions pour réduire le rythme actuel de la déforestation, le mécanisme REDD+ (Réduction des Émissions de gaz à effet de serre dues à la Dégradation et à la

Déforestation, augmentation des stocks et gestion durable des forêts) a été introduit lors de la 13^{ème} session de la Conférence des Parties en 2007 à Bali suite à des intenses négociations. Ce mécanisme implique le suivi de l'évolution des terres forestières afin de mesurer et vérifier les politiques, programmes et projets visant à conserver ou augmenter cette ressource (Verchot *et al.*, 2009). Les données et outils de télédétection sont indispensables pour atteindre ces objectifs (DeFries *et al.*, 2005; Gibbs *et al.*, 2007). Cependant malgré l'existence de lignes directrices (GOFC-GOLD, 2014; GIEC, 2006), les techniques de télédétection doivent être améliorées afin de permettre de surveiller des grandes surfaces forestières, d'une réduction de la fréquence de mesure et améliorer le niveau de précision sur les parcelles (*patches*) de déforestation.

Madagascar constitue des centres de biodiversité les plus importants du monde (Myers *et al.*, 2000), où les forêts tropicales humides couvraient 11,5 millions d'hectares dans les années 1950 (Harper *et al.*, 2007). Néanmoins, d'importantes menaces pèsent sur la flore, notamment par la destruction de l'habitat pour la pratique de « tavy » (culture sur brûlis).

Dans le cadre de la mise en œuvre de sa stratégie REDD+ pour minimiser ces menaces, Madagascar doit se doter d'estimations récentes de son couvert forestier et proposer des outils de mesure et suivi reproductible, fiable et efficient (GOFC-GOLD, 2014). L'écorégion des forêts humides a été identifiée comme prioritaire pour l'estimation de ses taux de déforestation et de ses stocks importants de carbone (RPP, 2014). Cette zone concentre également les principaux défis en termes de suivi de la déforestation par télédétection (relief, nuage, saisonnalité, étendue).

Ainsi, en 1990, le taux de la déforestation atteignait un niveau alarmant de 1% par an et les forêts humides ne couvraient plus que 5,6 millions d'hectares (Harper *et al.*, 2007). Ces chiffres ont été actualisés pour les périodes 1990 – 2005 (MEFT-CI, 2009) et 2005 – 2010 (MEFT-ONE-CI, 2013) à partir des analyses basées sur des images Landsat. Ces études ont montré que les surfaces des forêts humides diminuent entre les années 1990 – 2010 et le taux de déforestation montrait une légère baisse, passant de 0,8% par an entre 1990-2000 à 0,5 % par an pour la période 2000-2010. Ces études présentent toutefois deux limites importantes : i) la forte présence de nuages sur les images utilisées ne permet pas une information exhaustive et ii) l'Unité Minimum de Cartographie (UMC) définie à 1 hectare (incluant les forêts et déforestation) exclut les petites parcelles de défrichement.

En 2012, la carte de déforestation mondiale produite par l'Université du Maryland (Hansen *et al.*, 2013) a attiré une grande attention des scientifiques. Cependant, Tropek *et al.*, (2014) ont montré que cette carte surestime la couverture forestière et sous-estime le taux de déforestation au niveau local.

Le suivi de la déforestation des forêts humides à Madagascar par télédétection doit faire face à plusieurs défis. Les forêts se trouvent dans les régions montagneuses à l'Est de l'île sur les reliefs très accidentés, seul 5% de la superficie totale est plane (Rakotomalala *et al.*, 2012). Les parcelles de tavy sont généralement localisées sur les versants de faibles altitudes et difficiles à détecter avec les images satellites à cause des effets de reliefs sur ces images (Vieilledent *et al.*, 2013). Par ailleurs, les parcelles de défrichement ou de déforestation sont de petites tailles (0,6 hectare en moyenne (Grinand *et al.*, 2013)) compte tenu des fortes pentes et des difficultés d'accès. Ceci explique qu'avec les images Landsat actuellement disponibles pour ce type d'étude, il est difficile de détecter les parcelles de déforestation. Les parcelles de défrichement-brûlis se situant souvent à proximité l'une de l'autre spatialement, il faut que l'intervalle de temps soit suffisamment long pour que les petites surfaces concernées par la déforestation soient détectables. De plus, cette région est sujette à des fortes couvertures nuageuses limitant l'application de la télédétection optique pour l'analyse de l'évolution de la déforestation. Enfin, la vaste étendue de la zone d'étude demande à traiter un grand nombre d'images avec des dates d'acquisition différentes. Ceci pose des problèmes temporels car les saisons ont un impact fort en termes de phénologie et densité du couvert végétal. Une étude récente sur des sites pilotes REDD+ à Madagascar (Grinand *et al.*, 2013) a proposé des innovations méthodologiques i) pour la classification des images afin de gérer les effets de saisonnalité sur les images à classifier (approche multidate) et ii) pour le post-traitement afin de réduire la surface minimale détectée pour les parcelles de déforestation à 0,36 hectare tout en produisant une qualité de classification satisfaisante. Cependant cette étude pilote n'a pas été testée à une échelle nationale, ni sur des intervalles de temps de moins de 5 années.

L'objectif de cette étude a été de produire une carte du couvert forestier actualisée entre 2005 – 2010 – 2013 et évaluer la déforestation à l'échelle de l'écorégion des forêts humides de Madagascar. L'approche utilisée par Grinand *et al.*, (2013) a été adaptée pour de grandes étendues et pour des intervalles de temps réduits (Tableau 1). La carte finale de la déforestation a été validée à l'aide d'une photo-interprétation sur des images à haute résolution spatiale (SPOT 5 – 10 mètres) pour la période 2010 – 2013 (Corbane *et al.*, 2015).

2. Zone d'étude

Madagascar est une île d'une superficie de 590 000 km², situés dans l'Océan Indien et est caractérisée par quatre grands types d'écosystèmes forestiers définis sur les bases des différentes subdivisions phytogéographiques de l'Inventaire Écologie et Floristique Nationale (Humbert *et al.*, 1965): les forêts humides de l'est, les forêts sèches de l'ouest, les forêts épineuses du sud et enfin les mangroves (figure 1).

La présente étude concerne les forêts humides dont la définition officielle est de minimum 30% de couvert forestier, une hauteur de plus de 5 m et sur plus de 1 ha. Elle se situe sur le versant oriental du nord au sud de la grande île. Deux types de climat coexistent sur cette région (Cornet *et al.*, 1974) : le climat de type perhumide, à une altitude inférieure à 800 m et le climat de type humide, au-dessus de 800 m mais avec les sous-domaines écologiques suivants (White *et al.*, 1983):

- domaines de l'est et du Sambirano (0 – 800 m) : forêts denses humides sempervirentes de basse altitude et forêts littorales ;
- domaines du centre versants orientaux (800 – 1800 m) : forêts denses humides sempervirentes de moyenne altitude ;
- domaines du centre étage des montagnes (> 1800 m) : forêts sclérophylles de montagne et fourrés sclérophylles de montagne ;

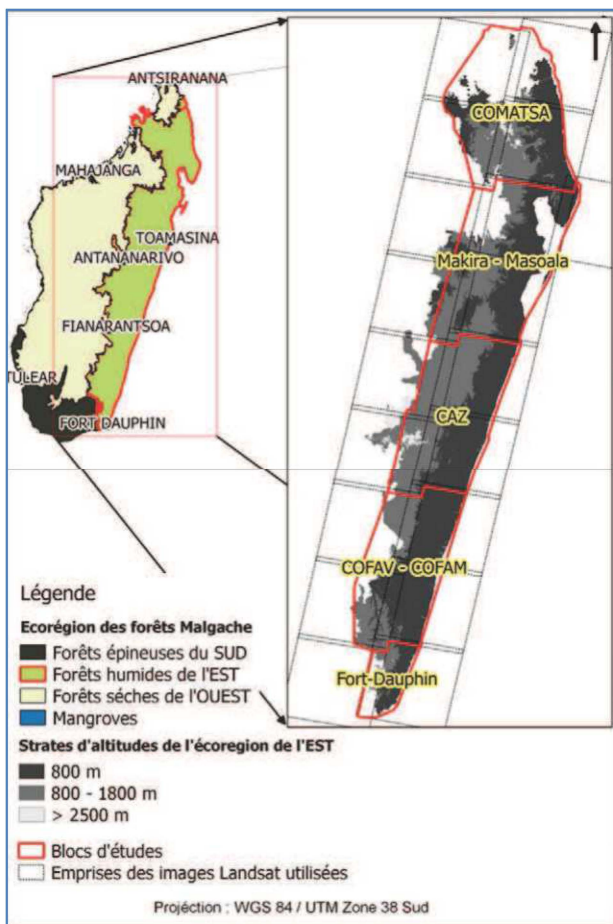


Figure 1 : Localisation de la zone d'étude, des emprises d'images Landsat et des blocs utilisés pour la photo-interprétation et le traitement des données. Les 5 blocs sont du nord au sud : Comatsa, Makira-Masoala, Caz, Cofav-Cofam et Fort-Dauphin.

3. Matériel et Méthodes

L'analyse multitemporelle d'images satellites a été utilisée dans cette étude en considérant l'approche « *Wall-to-Wall* » (GOFC-GOLD, 2014). La première étape consiste à la collecte et à la correction géométrique des images satellites. Des calculs des indices géomorphologiques et radiométriques ont été réalisés suivis de la délimitation des parcelles d'entraînement pour la classification supervisée pixel à pixel basée sur l'algorithme *RandomForest*. Deux procédures de validation ont été mises en place : i) « validation interne » lors de la phase d'apprentissage de l'algorithme et ii) « validation externe » à partir de la photo-interprétation d'un grand nombre de points sur un maillage régulier et différentes sources de données spatiales (données d'Hansen, SPOT – 5 et Landsat). Ces étapes sont présentées dans les paragraphes suivants.

3.1. Choix et collecte des images de référence

Les images Landsat utilisées dans cette étude ont été téléchargées dans les archives de l'USGS (<http://earthexplorer.usgs.gov> et <http://glovis.usgs.gov>). Les images ont été sélectionnées de façon à ce qu'elles aient moins de 20% de couverture nuageuse sur la totalité de la scène et moins d'un pixel de décalage spatial pour chaque année de références : 2005, 2010 et 2013. Les produits « *Global Land Survey* » (GLS) de Landsat 5 (pour 2005 – 2010) et L1T de Landsat 8 (pour 2013) ont été choisis afin d'obtenir des données corrigées du point de vue géométrique et radiométrique. En effet, d'après Gutman *et al.*, (2008), ces données disposent des qualités radiométriques et géométriques satisfaisantes pour effectuer des analyses de changement d'occupation du sol et notamment l'analyse historique de déforestation. Toutefois, le choix des produits GLS a été limité à cause de la couverture nuageuse sur quelques images. Dans certains cas, elles ont été remplacées par les images du satellite Landsat 7. Cependant, du fait d'une défaillance du capteur (*Scan Line Corrector ou SLC*) depuis 2003, les images Landsat 7 des années 2005 et 2010 présentent quelques centaines de mètres voire quelques kilomètres d'information manquante (*stripping*) même si elles ont de bonnes qualités géométrique et radiométrique (Barsi *et al.*, 2007). De ce fait, plusieurs images d'une même année de référence ont été fusionnées afin de combler ce défaut. Pour assurer la disponibilité et la bonne qualité des images, les dates d'acquisition ont été choisies à une année près de la référence (tableau 1).

Afin de faciliter les traitements de ces données, l'écorégion a été subdivisée en cinq blocs pour que quatre équipes travaillant dans ce projet puissent se partager le travail. Chaque bloc est constitué d'un maximum de cinq scènes d'images pour alléger le processus de traitement (figure 1).

3.2. Prétraitements

Les bandes de toutes les images téléchargées ont été compilées (*stacking*) en un seul fichier constituant ainsi une image multodate. Préalablement, une vérification de la précision géométrique a été faite visuellement sous ENVI et QGIS, dans le cas où un décalage supérieur à un pixel est observé, une rectification d'image à image a été réalisée en prenant comme image de référence les images GLS 2005. Les images ont été mosaïquées pour chaque année de référence et par blocs d'étude.

Ensuite, les mosaïques ont été projetées dans le système de projection : WGS 84 – UTM zones 38 Sud. Les scènes avec une faible couverture nuageuse ont été systématiquement mises au-dessus de celles qui présentent de nébulosité plus forte afin de minimiser la couverture nuageuse sur la carte finale.

Les décalages radiométriques dus aux différences des dates d'acquisition ont été minimisées en faisant une égalisation d'histogramme tout en prenant les images les plus nettes comme références.

Blocs d'étude	Références des scènes	Années de référence			Intervalle de temps (en années)	
		~ 2005	~ 2010	~ 2013	I1	I2
Comatsa	158 - 069	02/06/2004	09/08/2008	28/12/2013	4,19	5,39
	159 - 069	18/08/2006	10/06/2010	26/06/2013	3,81	3,05
	158 - 070	27/08/2006	05/10/2010	19/06/2013	4,11	2,71
	159 - 070	25/04/2005	10/06/2010	07/09/2013	5,13	3,25
Makira - Masoala	157 - 071	25/03/2005	04/11/2011	07/02/2014	6,62	2,26
	158 - 071	27/01/2005	20/05/2011	18/03/2014	6,31	2,83
	159 - 071	06/02/2006	05/05/2009	13/08/2013	3,24	4,28
	158 - 072	10/06/2007	18/01/2011	18/03/2014	3,61	3,16
	159 - 072	20/03/2004	30/04/2010	13/08/2013	6,12	3,29
Caz	158 - 073	11/06/2007	08/07/2011	18/05/2013	4,08	1,86
	159 - 073	28/04/2006	01/05/2010	25/05/2013	4,01	3,07
	158 - 074	24/06/2006	08/07/2011	18/05/2013	5,04	1,86
	159 - 074	25/04/2005	07/06/2009	25/05/2013	4,12	3,97
Cofav-Cofam	158 - 075	26/04/2005	15/11/2009	05/07/2013	4,56	3,64
	159 - 075	11/09/2006	30/03/2010	23/04/2013	3,55	3,07
	158 - 079	27/09/2006	09/11/2010	13/08/2013	4,12	2,76
	159 - 076	09/03/2005	15/11/2009	13/08/2013	4,69	3,75
Fort-dauphin	158 - 077	12/04/2006	20/04/2009	26/06/2013	3,02	4,19
	moyenne	07/12/2005	24/05/2010	20/08/2013	4,46	3,24

Tableau 1. Base de données des images Landsat utilisées pour l'analyse historique de la déforestation entre 2005-2010 et 2010-2013. I1 : Intervalle en nombre d'années décimales pour la période 2005 -2010 et I2 : Intervalle en nombre d'années décimales pour la période 2010 -2013.

3.3. Classification supervisée multodate

Dans la littérature scientifique, l'analyse bitemporelle est souvent adoptée pour la classification de la dynamique d'occupation du sol (Eastman *et al.*, 2009). Cependant lorsque deux cartes d'occupation du sol correspondant à deux dates différentes sont combinées, les erreurs individuelles sont multipliées si l'on considère que les erreurs des deux cartes sont indépendantes (Fuller *et al.*, 2003). Ainsi l'analyse multodate réduit les erreurs de classification par rapport à la comparaison de classifications produites pour plusieurs dates (GOFC-GOLD, 2014). Ceci nous a conduits à effectuer une classification supervisée sur des images multidates dans toute l'écorégion.

3.3.1. Définition des classes d'occupation des sols

Les classes d'occupation des sols et d'évolutions retenues se basent sur les recommandations de l'IPCC (2006) et des diverses études d'occupation du sol connues dans l'ensemble de l'écorégion (tableau 2).

Typologies des parcelles d'entraînement	Descriptions des classes de changement d'occupation du sol
FFF	Forêts « stables » entre 2005 et 2013 : Terres forestières humides intactes entre 2005 et 2013
FFP	Déforestation entre 2010 et 2013 : Terres forestières humides converties en Prairies/Terres cultivées entre 2010-2013
FPP	Déforestation entre 2005 et 2010 : Terres forestières humides converties en Prairies/Terres cultivées entre 2005-2010
FNN	Terres forestières en 2005 et Nuage/Ombre en 2010 et 2013
FFN	Terres forestières en 2010 et Nuage/Ombre en 2013
PPP	Prairies/Terres cultivées depuis 2005
HHH	Zones humides inchangées
AAA	Sols nus/sables/roches inchangés
MMM	Mangroves inchangées

Tableau 2. Typologie des classes d'évolution d'occupation du sol retenue pour la cartographie de la déforestation utilisé pour la photo-interprétation.

3.3.2 Délimitation des parcelles d'entraînement

L'approche de classification retenue étant une approche supervisée (cf 3.3.3), des parcelles d'entraînement sont nécessaires pour calibrer l'algorithme de classification. Elles ont été délimitées par photo-interprétation sur les images à classifier. Une composition colorée multibande de la bande spectrale rouge (bande numéro 3 de l'image Landsat) a été produite pour visualiser les différents typologies recherchés. Les parcelles ont été localisées en « grappes » (figure 2), c'est-à-dire par regroupement de plusieurs parcelles d'entraînement dans une même unité de paysage, ceci pour minimiser les confusions entre les classes de changements en délimitant bien les limites entre les typologies voisines.

L'échantillonnage des parcelles d'entraînement a été fait de façon raisonnée en valorisant surtout la connaissance sur terrain des équipes. Les grappes ont été réparties sur l'ensemble de l'image à classifier. Les contours ont été affinés et soigneusement vérifiés en les superposant sur les images satellites à très haute résolution disponibles dans Google Earth (Quickbird). Au final, les résultats de la photo-interprétation pour les trois dates étudiées ont été stockés dans une base de données géolocalisée (BDD parcelle d'entraînement (PE) au format shapefile) regroupant 2 700 polygones de 24 000 hectares au total. La taille médiane des polygones liés à la déforestation entre 2005 – 2010 (FPP) et 2010 – 2013 (FFP) est de 1,96 hectare et 1,9 hectare respectivement. Ces valeurs permettent de quantifier les surfaces moyennes défrichées annuellement en les divisant par les intervalles moyens présentés dans le tableau 1. Ce qui donne environ 0,5 hectare de taille moyenne d'une parcelle de *tavy*. Ce chiffre est comparable aux 0,6 hectare mesurés par Grinand *et al.*, (2013). Sur le terrain, il est probable que cette surface moyenne soit plus élevée si on tient en compte la pente, et qu'elle soit variable selon les régions (organisation individuelle ou collective pour le

tavy, mécanisation, etc.). La surface de défrichement annuelle est donc similaire à l'UMC.

3.3.3. Classification

L'algorithme *RandomForest* (RF), développé par Breiman *et al.*, (2001), a été sélectionné pour ses bonnes capacités prédictives de l'occupation du sol (Gislason *et al.*, 2006) et dans le cas d'analyse temporelle (Schneider *et al.*, 2012).

C'est un algorithme de classification supervisée non paramétrique qui combine l'algorithme d'arbres de décision et une technique d'agrégation (*bagging*). Il est présent dans package « *randomForest* » (Liaw *et al.*, 2002) du logiciel R. L'algorithme construit une multitude d'arbres de décision par tirage aléatoire d'observation (pixels) et de variables. L'affectation de la classe finale est réalisée par vote majoritaire à partir de l'ensemble des arbres.

Le choix des variables explicatives influe sur la qualité du modèle de classification. Afin d'améliorer la discrimination des classes étudiées, plusieurs indices dérivés des canaux primaires des images satellites ont été calculés en plus des variables radiométriques, notamment l'indice normalisé de végétation (NDVI, Rouse *et al.*, 1974), l'indice de réflectance du proche infrarouge (NIRI) et l'indice de teneur en eau par différence normalisée (NDWI, Gao *et al.*, 1996). En plus de ces indices radiométriques, des indices géomorphologiques (l'altitude, la pente et la rugosité) dérivés d'un Modèle Numérique de Terrain à 30 mètres de résolution ont été introduits dans le but d'atténuer l'effet de relief sur les réflectances des canaux primaires (Tachikawa *et al.*, 2011).

Ainsi, plusieurs modèles avec différentes combinaisons de variables ont été testés afin de déterminer la meilleure combinaison de variables pour la détection de la déforestation. Le choix de la meilleure combinaison s'est appuyé sur des indicateurs de performance lors de la validation interne décrite ci-après




Figure 2 : illustration du processus de photo-interprétation lors du choix des parcelles d'apprentissages.

a) Mise en évidence des changements de classes sur une composition colorée multibande des images Landsat : (R: Band3-2013; G: Band3-2010; B: Band3-2005). En vert clair, les déforestations entre 2005 et 2010 (FFP), en rouge, les déforestations entre 2010 et 2013 (FFP) et en vert sombre, les forêts « stables » depuis 2005 (FFF).

b) Délimitation des classes sur l'image Landsat 2013 à classifier (composition colorée : R: Band4; G: Band5; B: Band3). En orange foncé, les forêts, en orange clair les anciennes parcelles de déforestation (entre 2005 et 2010) et en cyan les nouvelles parcelles de déforestation observées sur l'image 2013;

c) Vérification et affinement sur Google Earth (décembre 2014), type d'image : satellite Quickbird (50 centimètres de résolution).

3.3.4. Validation interne de la classification

Le modèle a été construit en gardant les paramètres par défaut de l'algorithme RF, certains auteurs ayant montré qu'ils produisaient les meilleurs résultats (Rodriguez-Galiano, 2012). RF utilise les 2/3 (70%) du jeu de données d'apprentissage pour la calibration et les 1/3 (30%) restant pour la validation (production de la matrice de confusion et indicateurs de qualité). Sur la base de ces placettes de validation (30%), l'algorithme calcule un indicateur de performance du modèle, appelé erreur *Out-Of-the Bag* (OBB) (Bylander *et al.*, 2002). Plus cette erreur tend vers zéro, plus le modèle est bon. Outre cet indicateur, une matrice de confusion est produite pour évaluer la qualité « intrinsèque » du modèle. Elle permet de calculer les pourcentages d'erreur d'omission et de commission entre les diverses classes ainsi que l'indice Kappa (Cohen *et al.*, 1960 et Caloz *et al.*, 2001). Le modèle correspondant aux meilleurs indicateurs de qualité a été utilisé pour la classification de l'ensemble du bloc d'étude.

3.4. Post-classification

Une étape de post-classification a été implémentée afin de nettoyer l'image de classification brute, la faire

correspondre aux exigences d'UMC et réduire les erreurs. Ainsi, un filtre convolutif majoritaire de dimension 3 x 3 pixels a été utilisé. Ensuite, deux filtres majoritaires ont été appliqués consécutivement afin d'éliminer les "parcelles de forêt" inférieure à 1 hectare (soit 3x3 pixels sur une image Landsat) et les parcelles de déforestation (0,36 hectare soit 2x2 pixels).

Pour disposer d'une cartographie complète de l'écorégion sans nuages, nous nous sommes appuyés sur une source extérieure notamment les données issues de l'étude de Hansen *et al.*, (2013). Le pourcentage de couverture forestière en 2000 (*treecover*) ainsi que les pixels déforestés par année (*lossyear*) pour la période 2000 à 2012 produite par ces auteurs sont disponibles sur internet. Un seuil de 75% de couverture forestière a été appliqué pour estimer l'étendue forestière en 2000. Une carte de déforestation pour les périodes 2005 – 2010 et 2010 – 2012 a ensuite été créée à partir des pixels classés « déforestation ». En superposant la carte de déforestation produite dans le cadre de cette étude avec celle dérivée d'Hansen *et al.*, (2013), il a été possible d'éliminer les pixels identifiés comme ombres et nuages. Cette étape est résumée dans la figure 3.



Figure 3. a) : Résultat de classification après filtrages avec les classes nuage et ombre (en vert clair) ; b) Carte forestière dérivée des données de Hansen *et al.*, (2013); c) Combinaison de a) et b) pour produire la carte finale sans nuages entre 2005 et 2013 du PERR-FH (en vert les forêts intactes en 2013, en orange la déforestation entre 2005 - 2010 et en rouge la déforestation entre 2010 – 2013).

3.5. Validation externe des résultats

Cette étape consiste en une confrontation statistique du résultat de la classification précédente (issue des images LANDSAT) avec le résultat de l'observation d'images satellites sur des points d'échantillonnage (approche « *point sampling* ») et pour deux dates historiques (2010 et 2013). Le choix de la localisation des points et les images à photo-interpréter ont été définis de manière à être complètement indépendants de la carte à valider.

L'échantillonnage de points a été réalisé sur des images à haute résolution : SPOT 5 de 10 mètres de résolution et sur des images LANDSAT de 30 mètres de résolution. Les images SPOT ont été commandées

et collectées via la station « Surveillance de l'Environnement assisté par Satellite - Océan Indien » (SEAS-OI) pour la plupart des cas et dans certains cas à partir de la base de données image *Planet Action*. Au final, quatre régions sont couvertes par ces images à haute résolution et pour deux dates historiques (figure 4).

Une carte des pertes forestières a été produite sur la base des données de Hansen *et al.*, (2013). Un échantillonnage régulier sur une grille carrée de 20 km x 20 km a ensuite été réalisé entre 2005 – 2012 afin d'identifier les régions à forte pression de déforestation (*hot spot*). Pour se focaliser sur ces zones, la carte a été subdivisée en trois catégories selon l'intensité de la déforestation (tableau 3).

Intensité de la déforestation [ha/an] d'après Hansen et al (2013)	Niveau de pression de la déforestation	Espacement du semis de point [km]
< 20	Faible	5 x 5
20 - 50	Moyenne	1 x 1
> 50	Forte	0,5 x 0,5

Tableau 3 : Espacement du semis de points régulier utilisé pour la validation externe selon la pression de la déforestation issue des données d'Hansen *et al.*, (2013).

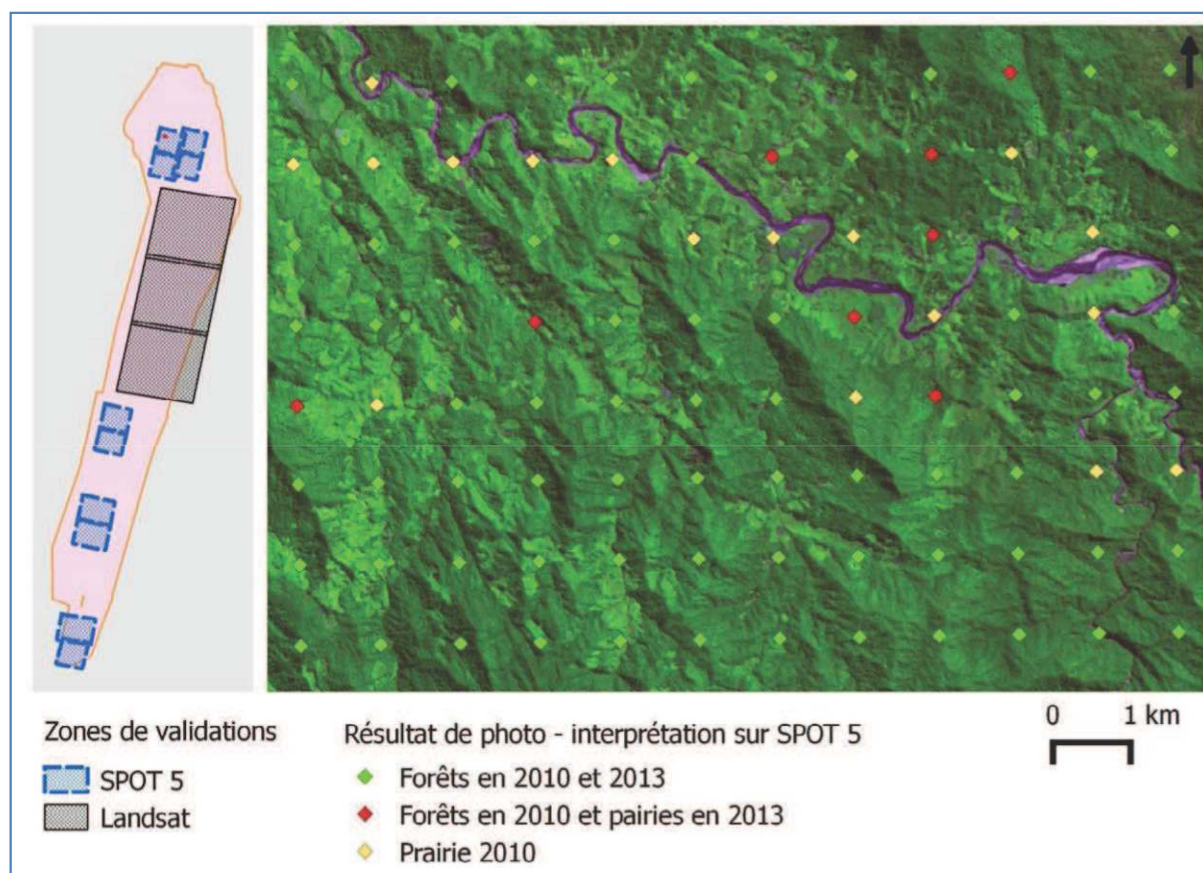


Figure 4. Illustration du processus de validation externe. À gauche : zones de validation et à droite, extrait d'une grille d'échantillonnage (1 kilomètre) sur des images SPOT 5 pour le bloc Comatsa. (Images distribuées par SEAS-OI © CNES. Distribution Astrium Services / Spot image S.A., France, tous droits réservés).

3.6. Calcul du taux de déforestation

Le taux de déforestation annuel résulte du rapport entre la surface défrichée sur une période, divisée par la surface forestière initiale et par le nombre d'années de la période (Menon *et al.*, 1997, Ramesh *et al.*, 1997, Narendra Prasad *et al.*, 1998). Cependant, plusieurs publications ont récemment mis en lumière que l'évolution de la perte forestière ne peut pas être obtenue avec ce simple rapport (Puyravaud *et al.*, 2002). La formule standardisée proposée par Puyravaud *et al.*, (2002) a été adoptée pour calculer le taux de déforestation annuel pour cette étude (équation 1).

$$\theta = -\frac{1}{t_2 - t_1} \ln \left(\frac{A_2}{A_1} \right) * 100 \quad (1)$$

Avec

A1= superficie forestière de l'année initiale

A2 = superficie forestière de l'année finale

t1 = date d'acquisition exacte de l'image pour l'année initiale

t2= date d'acquisition exacte de l'image pour l'année finale

Ce mode de calcul demande de connaître exactement l'intervalle entre les deux dates (t1 et t2). Comme on l'a vu précédemment (tableau 1), cette étude historique de la déforestation, comme toute autre étude, n'utilise pas une seule date (jour dans l'année) par année pivot, il existe des intervalles de temps variables selon les scènes dont il faut prendre en compte. Pour calculer le taux annuel de déforestation d'une région couverte par plusieurs (N) scènes, la méthode adoptée a été de calculer la moyenne pondérée des taux de déforestation par scène (équation 2) afin de palier au problème lié à l'intervalle de temps qui n'est pas toujours le même pour chaque scène d'images (tableau 1). Les coefficients de pondération ont été obtenus en faisant le rapport de la surface de la forêt sur la scène concernée avec la surface totale de la forêt sur la région concernée (équation 3).

$$\theta_r = \frac{1}{S_T} \sum_{i=1}^N \omega_i \cdot \theta_i \quad (2)$$

$$\text{Avec } \omega_i = \frac{S_i}{S_T} \quad (3)$$

Où :

θ_i : Taux de déforestation dans une scène

« i » appartenant à la zone concernée

θ_r : Taux de déforestation d'une région

S_i : Surface totale de la forêt dans une scène

S_T : Surface totale de la forêt dans la région

ω_i : Coefficients de pondération

4. Résultats

4.1. Choix du modèle et validation interne

Les résultats des différents tests effectués sur trois familles de variables avec cinq combinaisons différentes sont présentés dans le tableau 4. Ce test a été réalisé sur le bloc Comatsa avec 493 parcelles d'entraînement. On observe qu'en utilisant les 6 bandes spectrales des images satellitaires (modèle 1), l'OOB du modèle est estimé à 3,86 %. Lorsque l'on ajoute les indices d'occupations du sol (NDVI, NIRI et NDWI) avec ces bandes spectrales (modèle 2), le modèle s'améliore, mais très légèrement, avec une OOB de 3,45%. Ainsi le fait d'ajouter ces néocanaux n'apporte pas plus d'information dans le modèle. Inversement, le fait d'ajouter des variables géomorphologiques améliore considérablement le modèle (modèle 3), avec une erreur OOB inférieure à 3. Par ailleurs, le fait d'enlever les bandes 1 et 2 et de rajouter les indices d'occupations du sol a augmenté l'erreur dans le modèle 4.

Au final, le modèle 5 a été retenu pour l'ensemble des blocs puisqu'il intègre les indices d'occupation du sol parmi les covariables alors que le modèle 3, malgré ses indices de qualité très légèrement supérieurs, est fortement influencé par l'importance des variables géomorphologiques. Les indices de précision des modèles de classification pour chaque bloc sont présentés dans le tableau 5.

4.2. Validation externe de la cartographie

La validation externe s'est appuyée sur 10 854 points photo-interprétés sur des images SPOT. Le tableau 6 présente la matrice de confusion liée à cette validation. L'indice Kappa est de 79% et la précision globale se situe à 88%.

Modèle testé		1	2	3	4	5
	Bandes spectrales	1,2,3,4,5,7	1,2,3,4,5,7	1,2,3,4,5,7	3,4,5,7	3,4,5,7
Variables explicatives	Indices d'occupation du sol		ndvi, niri, ndwi		ndvi,niri, ndwi	ndvi,niri, ndwi
	Indices morphologiques			altitude, rugosité, pente		altitude, rugosité, pente
Indices de précisions du modèle	OOB	3,86%	3,45%	2,37%	4,51%	2,56%
	Kappa	94,77%	95,33%	96,80%	93,89%	96,54%

Tableau 4 : Qualité interne pour cinq modèles construits à partir de combinaisons de variables explicatives.

Indicateurs / blocs	Comatsa	Makira-Masoala	Caz	Cofav-Cofam	Fort Dauphin
OOB	2,90%	2,30%	3,61%	1,39%	2,15%
Kappa	96,38%	97,23%	95,71%	97,44%	97,16%
Nombre de parcelles d'entraînement	493	796	568	394	396

Tableau 5: Validation interne du modèle de classification retenu (modèle 5) : Indices de qualité pour chaque bloc d'étude.

Catégories de la carte finale	Observation par photo-interprétation sur images SPOT					Précision utilisateur [%]
	FF	FP	PP	Total	Erreur de commission [%]	
FF	5154	145	542	5841	12	88
FP	34	273	58	365	25	75
PP	372	53	4223	4648	9	91
Total	5560	471	4823	10854		
Précision producteur [%]	93	58	88			

Tableau 6: Matrice de confusion externe pour la validation de la carte historique de déforestation pour la période 2010 – 2013 (sur 10 854 points de contrôle). FF : forêt en 2010 et 2013 ; FP : forêt en 2010 et prairie en 2013 ; PP : prairie en 2010 et 2013.

4.3. Analyse de la déforestation et tendances

La cartographie de l'évolution du couvert forestier est présentée dans la figure 5. Le tableau 7 présente les superficies de la couverture de forêts naturelles et les taux de déforestation observés dans toute l'écorégion des forêts humides et dans deux strates d'altitude. Ces résultats montrent que plus de 95 000 ha de forêts par an ont été perdus pour la période 2005 - 2010 et environ 110 000 ha par an pour la période 2010 – 2013.

Le taux annuel de déforestation pour l'écorégion des forêts humides a quasiment doublé entre les deux périodes : 2005 – 2010 et 2010 – 2013. La strate des forêts de basse altitude est visiblement la plus touchée par la déforestation depuis plusieurs années. Par ailleurs, la strate des forêts de moyenne altitude semble moins marquée par la déforestation. Néanmoins, les taux de déforestation y ont aussi doublé et y présentent aujourd'hui des valeurs assez proches de celles observées à basse altitude.

Zone	Surface de la couverture forestière (en milliers d'hectares)		Taux de déforestation (% par an)		
	2005	2010	2013	2005- 2010	2010- 2013
Toute l'écorégion	4 556	4 457	4 345	0,50	0,94
Strate 0 – 800	1 712	1 666	1 616	0,60	1,15
Strate 800 et +	2 844	2 790	2 729	0,44	0,82

Tableau 7: Superficies et taux annuels de déforestation (issus de la classification par Random Forest) par catégorie d'altitude pour les deux périodes observées : 2005 – 2010 et 2010 – 2013.

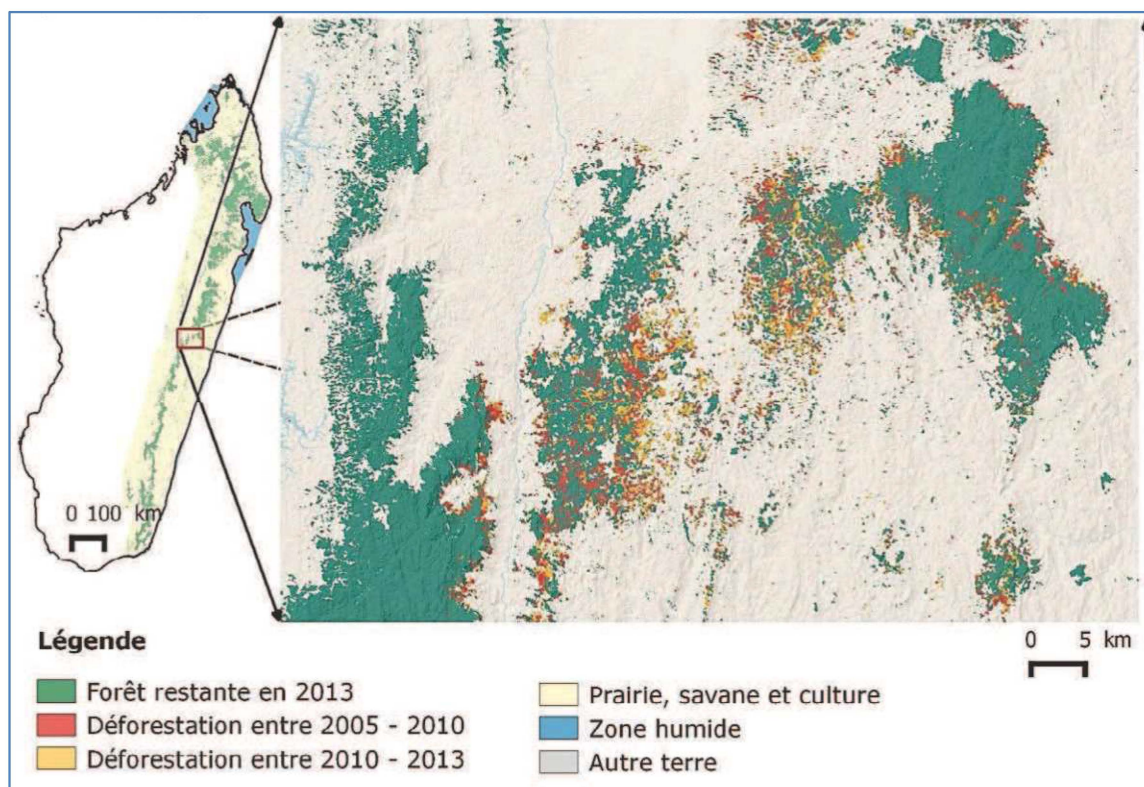


Figure 5: Carte de l'historique de la déforestation dans l'écorégion humide de l'Est de Madagascar avec un zoom sur une zone à forte intensité de déforestation (hot-spot) superposée sur une carte d'ombrage.

5. Discussions

5.1. Paramétrage et qualité du modèle

D'après Pontius *et al.*, (2000), lorsque l'indice Kappa d'un modèle de classification est compris entre 0,50 et 0,75 le modèle peut être exploité. Les résultats de la validation interne que nous avons pour chaque bloc dépassent largement cette limite. Par ailleurs, Rodriguez-Galiano *et al.*, (2012) suggèrent que l'indice OOB peut être considéré comme étant un indice de précision de classification non biaisé, mais il est compromis lorsque la précision globale de classification est faible (<50%). Par contre, si la précision globale est particulièrement élevée (supérieure à 90%), il est préférable de l'associer avec les indices Kappa dans l'évaluation d'un modèle.

En outre, il est clair que la qualité d'un modèle RF est très dépendante de la qualité des données d'entraînement (Gislason *et al.*, 2006). C'est la raison pour laquelle les parcelles d'entraînement ont été

construites en grappe dans cette étude pour que les frontières entre les typologies voisines soient bien délimitées (figure 2). Dans ce sens, il est important de noter que la photo-interprétation est dépendante de l'opérateur, de ce fait, il est préférable que deux photo-interprètes s'en occupent pour minimiser les erreurs. Cette technique est fastidieuse, critique en ressource humaine et consommatrice de temps, mais nécessaire pour garantir la fiabilité des résultats.

Grinand *et al.*, (2013) ont utilisé la combinaison de variable du modèle 4. Pourtant, ce modèle n'est pas le plus optimal d'après nos résultats. Nous avons observé que le fait d'associer à ce modèle les indices morphologiques diminue l'erreur (modèle 5). Par ailleurs, d'autres méthodes de sélection de variables utilisant l'algorithme *RandomForest* ont été testées dans d'autres études comme dans Genuer *et al.*, 2010.

5.2. Validation de la cartographie

La précision globale de la classification est compatible avec d'autres études utilisant des images Landsat comme images de base pour la classification (Duveiller *et al.*, 2008; Huang *et al.*, 2009). Ces auteurs ont obtenu des précisions globales (PG) supérieures à 90%. Nous avons obtenu ici une précision globale d'environ 90%. La validation mise en œuvre dans cette étude est particulièrement importante puisque les points de références sont indépendants du résultat de classification. En effet, cette validation a été faite en utilisant des images SPOT – 5 qui sont différentes spatialement et spectralement aux images Landsat utilisées pour la classification. De plus, les opérateurs qui ont délimité les parcelles d'entraînement sont différents de ceux qui ont photo interprété les points de validation sur les images SPOT.

5.3. Prise en compte de l'intervalle de temps dans le calcul du taux de déforestation

Les taux de déforestation de chaque bloc ont été calculés en prenant en compte la surface forestière relative sur chaque scène (pondération). Des approches différentes peuvent être utilisées, notamment en pondérant par la surface de la scène concernée ou simplement en divisant par un intervalle de temps unique, moyen sur la zone. La comparaison de ces trois modes de calculs (tableau 8) montre des

taux similaires dans les deux premiers cas et des résultats sensiblement différents lorsque l'on prend un intervalle de temps unique. Ces résultats confirment l'importance de considérer l'intervalle de temps dans le calcul de taux. Dans cette étude de déforestation historique, ainsi que dans d'autres sur Madagascar (MEFT-CI, 2009 et MEFT-CI-ONE, 2014), des écarts de plus d'une année entre deux scènes contigües sont observés du fait des contraintes de disponibilité des données exploitables en archive.

5.4. Comparaison avec d'autres études historiques de déforestation

Il est difficile de comparer les résultats de cette étude avec ceux des études similaires à l'échelle du pays puisque les méthodologies et les données utilisées ne sont pas compatibles (données, méthodologie, post-traitements). Toutefois, MEFT-CI (2009) ont estimé que le taux de déforestation pour la période 2005 – 2010 est à 0,5% par an pour les forêts humides. Ce taux est comparable avec ce qui est estimé dans cette étude (0,5% par an). Pour la période 2010 – 2013, le taux de la déforestation dans cette étude est proche du taux de la déforestation entre 1990 – 2000 (0,8% par an) (MEFT-CI, 2009), qui est également le taux maximum que le pays a connu depuis les dernières décennies.

Méthode de calcul du taux de déforestation	Taux de déforestation (% de surface par an)	
	2005- 2010	2010 - 2013
Intervalle de temps unique pour toute la région	0,23	0,92
Intervalle pondéré par la surface de la scène	0,26	0,91
Intervalle pondéré par la surface forestière de la scène	0,28	0,91

Tableau 8 : Comparaison des taux de déforestations dans le bloc Comatsa selon différents modes de calcul de l'intervalle de temps.

6. Conclusions et perspectives

Cette étude a permis d'actualiser les statistiques du couvert forestier et d'évaluer le rythme de la déforestation des forêts humides de l'Est de Madagascar. Elle met en lumière un taux de déforestation important (0,5 % par an entre 2005 – 2010 et 0,9% par an entre 2010 – 2013) entre les deux périodes considérées, de nature à alerter toutes les parties prenantes œuvrant en faveur de la préservation des ressources naturelles et de la biodiversité à Madagascar. Couplée à un travail rigoureux de délimitation de parcelles d'entraînement par photo-interprétation, cette étude permet de fournir une méthode de suivi de la dynamique forestière des forêts tropicales humides. L'ensemble des données et de la méthodologie mise en œuvre dans la présente étude permet de détecter des changements fins d'occupation

du sol de manière fiable et d'envisager la réduction de la fréquence de suivi du couvert forestier à 3 ans. Cependant, si on veut réduire la fréquence de suivi de la déforestation et considérant des erreurs géométriques d'un pixel en moyenne, l'usage des images Landsat pourrait ne pas être satisfaisant compte tenu de sa résolution spatiale assez faible par rapport aux petites parcelles de déforestation à détecter. Afin d'augmenter la fréquence de suivi (à 1 ou 2 ans) tout en gardant la précision de la cartographie, le recours à des images de plus haute résolution spatiale (10 mètres) sera nécessaire. À ce titre, la disponibilité d'images de meilleures résolutions comme SPOT 6 ou Sentinel-2 pourra être très bénéfique pour l'analyse et le suivi de l'évolution de la couverture forestière à Madagascar. Ainsi, il serait possible de faire la détection de petites parcelles de *tavy* et maintenir une haute qualité des résultats.

Remerciements

Cette étude a été menée dans le cadre du Projet Eco-Régional REDD+ - Forêts Humides (PERR-FH) et a été financée via le Fonds Additionnel du Programme Environnemental III, et dans la continuité des travaux menés par le Programme Holistique de Conservation des Forêts (PHCF) financé par l'Agence Française de Développement et Air France. Les auteurs tiennent à remercier tous les membres du Consortium (WCS, ONE, MNP, Etc Terra) pour leur contribution dans la réalisation de cette étude.

Références

- Achard, F., Eva, H., Stibig, H., J., Mayaux, P., Gallego, J., Richards, T., and Malingreau, J.P., 2002. *Determination of deforestation rates of the world's humid tropical forests*. Science, 297:pp 999-1003.
- Breiman, L., 2001. Random Forests, Machine Learning, 45(1):pp 5-32
- Breiman, L. 2002. *Manual on setting up, using, and understanding random forests v3. 1*. Technical Report, <http://oz.berkeley.edu/users/breiman>, Statistics Department University of California Berkeley, 29p.
- Bylander, T. 2002. *Estimating generalization error on two-class datasets using out-of-bag estimates*. Machine Learning, 48: pp 287–297.
- Caloz, R., and Collet, C., 2001. *Précis de Télédétection, Traitements numériques d'images de télédétection*, vol. 3, Université de Québec, Agence Universitaire de la Francophonie. 385p
- Cornet, A., 1974. *Essai de cartographie bioclimatique à Madagascar*. Notice explicative ORSTOM, 55: p 28. Paris, France.
- Corbane, C., Lang, S., Pipkins, K., Alleaume, S., Deshayes, M., García Millán, V. E., and Michael, F., 2015. *Remote sensing for mapping natural habitats and their conservation status – new opportunities and challenges*. International Journal of Applied Earth Observation and Geoinformation, 37: pp 7-16. <http://doi.org/http://dx.doi.org/10.1016/j.jag.2014.11.005>
- Cohen, J., 1960. A coefficient of agreement for nominales scales, Educational and Psychological Measurement, vol. 20, 1: pp 37 – 46
- DeFries, R., Asner, G. P., Achard, F., Justice, C. O., LaPorte, N., Price, K., Small, C., and Towshend, J. 2005. *Monitoring tropical deforestation for emerging carbon markets*, P. Mountinho and S. Schwartzman, editors. Tropical Deforestation and Climate Change. IPAM and Environmental Defense, Belem, Brazil and Washington, DC, pp 35-44
- Duveiller, G., Defourny, P., Desclée, B., and Mayaux, P., 2008. *Deforestation in Central Africa*: Estimates at regional, national and landscape levels by advanced processing of systematically-distributed Landsat extracts. Remote Sensing of Environment, 112: pp 1969–1981.
- Foody, G. M., 2010. *Assessing the accuracy of land cover change with imperfect ground reference data*. Remote Sensing of Environment, 114: pp 2271–2285.
- Eastman, J.R., Sangermano, F., Ghimire, B., Zhu, H., Chen, H., Neeti, N., Cao, Y., and Crema, S., 2009. *Seasonal Trend Analysis of Image Time Series*, International Journal of Remote Sensing, 10:pp 2721-2726.
- Fuller, R. M., Smith, G. M., and Devereux, B. J. 2003. *The characterization and measurement of land cover change through remote sensing: Problems in operational applications?* International Journal of Applied Earth Observation and Geoinformation, 4: pp 243–253.
- Gao, B.C., and Goetz, A.F.H., 1995. *Retrieval of equivalent water thickness and information related to biochemical components of vegetation canopies from AVIRIS data*. Remote Sensing of Environment, 52:pp 155–162.
- Genuer, R., Poggi, J.-M., and Tuleau-Malot, C. 2010. *Variable selection using random forests*. Pattern Recognition Letters, 31: pp 2225–2236
- Gibbs, H.K., S. Brown, J. O., Niles, and Foley, J.A., 2007. *Monitoring and Estimating Tropical Forest Carbon Stocks: Making REDD a Reality*. Environmental Research Letters 2 (4): 045023.
- GIEC, 2007 : *Bilan 2007 des changements climatiques. Contribution des Groupes de travail I, II et III au quatrième Rapport d'évaluation du Groupe d'experts intergouvernemental sur l'évolution du climat*. [Pachauri, R.K., Reisinger, A.]. GIEC, Genève, Suisse, 103 p.
- Gislason, P. O., Benediktsson, J. A., and Sveinsson, J. R., 2006. Random forests for land cover classification. *Pattern Recognition Letters*, 27:pp 294–300.
- Gutman, G., Byrnes, R., Masek, J., Covington, S., Justice, C., Franks, S., and Headley R. 2008. *Towards monitoring land cover and land-use changes at a global scale*. The Global Land Survey 2005, Photogrammetric Engineering and Remote Sensing, 74:pp 6-10,
- Grinand, C., Rakotomalala, F., Gond, V., Vaudry, R., Bernoux, M., and Vieilledent, G. 2013. *Estimating deforestation in tropical humid and dry forests in Madagascar from 2000 to 2010 using multi-date Landsat satellite images and the random forests classifier*. Remote Sensing of Environment, 139: 68–80. <http://dx.doi.org/10.1016/j.rse.2013.07.008>.
- GOFC-GOLD, 2014. *A sourcebook of methods and procedures for monitoring and reporting anthropogenic greenhouse gas emissions and removals associated with deforestation, gains and losses of carbon stocks in forests remaining forests, and forestation*. GOFC-GOLD Report version COP20-1, (GOFC-GOLD Land Cover Project Office, Wageningen University, The Netherlands).
- Hansen, M. C., Potapov, P. V., Moore, R., Hancher, M., Turubanova, S. A., Tyukavina, A., Thau, D.,

- Stehman, S. V., Goetz, S. J., Loveland, T. R., Kommareddy, A., Egorov, A., Chini, L., Justice, C. O., and Townshend, J. R. G. 2013. *High-Resolution Global Maps of 21st-Century Forest Cover Change*. Science, 342: pp 850–53.
- Harper, G., Steininger, M. K., Tucker, C. J., Juhn, D., and Hawkins, F. 2007. *Fifty years of deforestation and forest fragmentation in Madagascar*. Environmental Conservation, 34: pp 1–9.
- Huang, C., Kim, S., Song, K., Townshend, J. R. G., Davis, P., and Alstatt, A. 2009. *Assessment of Paraguay's forest cover change using Landsat observations*. Global and Planetary Change, 67: pp 1–12.
- Humbert, H. 1965. *Description des types de végétation* In : HUMBERT, H. & COURS-DARNE, G. (eds.). Notice de la carte de Madagascar. Travaux de Section Scientifique et Technique de l'Institut Français de Pondichéry. Institut Français de Pondichéry, 6: pp 46–78.
- IPCC, 2006. 2006 IPCC *Guidelines for National Greenhouse Gas Inventories*, Main, vol. 2, p. 12
- Liaw, A., and Wiener, M., 2002. *Classification and Regression by randomForest*. R news, 2: pp 18–22.
- Myers, N., Mittermeier, R.A., Mittermeier, C.G., da Fonseca, G.A.B., and Kent J. 2000. Biodiversity hotspots for conservation priorities. Nature, 403: pp 853–858.
- MEFT, Ministry of the Environment, Forest and Tourism of Madagascar, 2009. *Evolution de la couverture de forêts naturelles à Madagascar, 1990–2000–2005*. Antananarivo, Madagascar: USAID-CI, p132.
- MEFT, ONE, CI, 2013. *Evolution de la couverture des forêts naturelles à Madagascar, 2000 – 2005 – 2010*. ONE-CI-MEFT, p 11.
- Menon, S., and Bawa, K.S., 1997. *Application of geographic information systems, remote sensing, and landscape ecology approach to biodiversity conservation in Western Ghats*. Curr.Sci, 75: pp 228–285
- Narendra Prasad, S. 1998. *Conservation planning for the Western Ghats of Kerala. II. Assessment of habitat loss and degradation*. Curr. Sci, 75: pp 228–285.
- Puyravaud, J. P. 2002. *Standardizing the calculation of the annual rate of deforestation*. Forest Ecology and Management, 177: pp 593–596.
- Pontius, R.G.Jr. 2000. *Quantification error versus location in comparison of categorical maps*. Photogrammetric Engineering and Remote Sensing vol. 66, 8 : pp 1011–1016.
- Rakotomalala, F. 2012. *Evaluation de l'apport d'images à Très Haute Résolution Spatiale pour la modélisation de l'occupation du sol: cas du Complexe d'Aires Protégées de Zahamena*. Mémoire de DEA, faculté des sciences, Université d'Antananarivo. p 20
- Ramesh, B.R., Menon, S., and Bawa, K.S., 1997. *A Vegetation based approach to biodiversity gap analysis in the Agasthyamalai region, Western Ghats, India*. Ambio, 26: pp 536–539
- Rodriguez-Galiano, V. F., Ghimire, B., Rogan, J., Chica-Ojeda, M., and Rigol-Sanchez, J. P. 2012. *An assessment of the effectiveness of a random forest classifier for land-cover classification*. ISPRS Journal of Photogrammetry and Remote Sensing, 67: pp 93–104.
- Rouse Jr., J. W., Haas, R. H., Schell, J. A., and Deering, D. W. 1973. *Monitoring vegetation systems in the Great Plains with ERTS*. In S. C. Freden, E. P. Mercanti, & M. Becker (Eds.), Third Earth Resources Technology Satellite-1 Symposium. Technical presentations, section A, vol. I, pp. 309 – 317. Washington, DC: National Aeronautics and Space Administration (NASA SP-351).
- RPP-Madagascar, 2014. *Proposition des mesures pour l'état de préparation (Readiness - Preparation - Proposal)*, [cabinet Soritra, ONF-International et le CT-REDD], version Juin 2014, p39.
- Schneider, A. 2012. *Monitoring land cover change in urban and peri-urban areas using dense time stacks of Landsat data and data mining approach*. Remote Sensing of Environment, 124: pp 689–704.
- Tachikawa, T., Manabu K., and Akira I. 2011. *ASTER GDEM Version 2 Validation Report*. In International Geoscience and Remote Sensing Symposium (IGARSS). pp. 1–24.
- Teillet, P. M., Helder, D. L., Ruggles, T. A., Landry, R., Ahern, F. J., Higgs, N. J., and Palluconi, F. D. 2004. *A definitive calibration record for the Landsat-5 thematic mapper anchored to the Landsat-7 radiometric scale*. Canadian Journal of Remote Sensing, 30(4): pp 631–643.
- Tropek, R., Jan B., Petr K., Zuzana M., Irena, Š., and David S. 2014. *Comment on "High-resolution global maps of 21st-century forest cover change"*. Science (New York, N.Y.) 344 (6187): p 981. doi:10.1126/science.1248753.
- Verchot, L., and Petkova, E. 2009. *The State of REDD Negotiations: Consensus Points, Options for Moving Forward and Research Needs to Support the Process*. Bogor: CIFOR. pp 1–24.
- Vieilledent, G., Grinand, C., and Vaudry, R. 2013. *Forecasting deforestation and carbon emissions in tropical developing countries facing demographic expansion: a case study in Madagascar*. Ecology and Evolution, 3(6): pp 702–1716
- Williams, M. 2002. *Deforesting the Earth: From Prehistory to Global Crisis*. Annals of the Association of American Geographers, 96(3): pp 674–75.
- White, F., 1983. *The vegetation of Africa, a descriptive memoir to accompany the UNESCO/AETFAT/UNSO vegetation map of Africa*. UNESCO, Natural Resource. Res, 20: pp 1–356

Bioclimatic envelope models predict a decrease in tropical forest carbon stocks with climate change in Madagascar

Ghislain Vieilledent^{1*}, Oliver Gardi^{2,3}, Clovis Grinand⁴, Christian Burren⁵, Mamitiana Andriamanjato⁶, Christian Camara⁷, Charlie J. Gardner^{8,9}, Leah Glass¹⁰, Andriambolantsoa Rasolohery¹¹, Harifidy Rakoto Ratsimba¹², Valéry Gond¹ and Jean-Roger Rakotoarijaona¹³

¹Cirad – UPR BSEF, F-34398 Montpellier, France; ²Helvetas Swiss Intercooperation – BP 3044, 101 Antananarivo, Madagascar; ³Bern University of Applied Sciences – HAFL, CH-3052 Zollikofen, Switzerland; ⁴ETC Terra, F-75020 Paris, France; ⁵Wildlife Conservation Society, Soavimbahoaka, 101 Antananarivo, Madagascar; ⁶Ministère de l'Environnement et des Forêts – Direction Générale des Forêts, 101 Antananarivo, Madagascar; ⁷Missouri Botanical Garden, BP 3391, 101 Antananarivo, Madagascar; ⁸WWF – Madagascar and Western Indian Ocean Programme Office, BP 738, 101 Antananarivo, Madagascar; ⁹School of Anthropology and Conservation, University of Kent – Durrell Institute of Conservation and Ecology, Canterbury, Kent, UK; ¹⁰Blue Ventures – Blue Forests program, Ambanja, Madagascar; ¹¹Conservation International – Africa and Madagascar Field Division, 101 Antananarivo, Madagascar; ¹²Université d'Antananarivo – Département des Eaux et Forêts, BP 175, 101 Antananarivo, Madagascar; and ¹³ONE, Antaninarenina, BP 822, 101 Antananarivo, Madagascar

Summary

1. Recent studies have underlined the importance of climatic variables in determining tree height and biomass in tropical forests. Nonetheless, the effects of climate on tropical forest carbon stocks remain uncertain. In particular, the application of process-based dynamic global vegetation models has led to contrasting conclusions regarding the potential impact of climate change on tropical forest carbon storage.

2. Using a correlative approach based on a bioclimatic envelope model and data from 1771 forest plots inventoried during the period 1996–2013 in Madagascar over a large climatic gradient, we show that temperature seasonality, annual precipitation and mean annual temperature are key variables in determining forest above-ground carbon density.

3. Taking into account the explicative climate variables, we obtained an accurate ($R^2 = 70\%$ and $RMSE = 40 \text{ Mg ha}^{-1}$) forest carbon map for Madagascar at 250 m resolution for the year 2010. This national map was more accurate than previously published global carbon maps ($R^2 \leq 26\%$ and $RMSE \geq 63 \text{ Mg ha}^{-1}$).

4. Combining our model with the climatic projections for Madagascar from 7 IPCC CMIP5 global climate models following the RCP 8.5, we forecast an average forest carbon stock loss of 17% (range: 7–24%) by the year 2080. For comparison, a spatially homogeneous deforestation of 0.5% per year on the same period would lead to a loss of 30% of the forest carbon stock.

5. *Synthesis.* Our study shows that climate change is likely to induce a decrease in tropical forest carbon stocks. This loss could be due to a decrease in the average tree size and to shifts in tree species distribution, with the selection of small-statured species. In Madagascar, climate-induced carbon emissions might be, at least, of the same order of magnitude as emissions associated with anthropogenic deforestation.

Key-words: carbon storage, climate change, deforestation, Madagascar, MODIS, plant–climate interactions, REDD+, species shifting, tree height, tropical forest

*Correspondence author: E-mail: ghislain.vieilledent@cirad.fr

Introduction

Carbon sequestration by tropical forests plays an important role in the regulation of atmospheric CO₂ and global climate change (Houghton 2005; Pan *et al.* 2011). The current carbon stock in the world's forests is estimated to be 861 ± 66 Pg C (1 Pg = 10^{15} g), with 55% of this carbon (471 ± 93 Pg C) being stored in tropical forests (Pan *et al.* 2011). Tropical anthropogenic deforestation is thus responsible for a considerable proportion (6–17%) of global carbon dioxide emissions that affect climate change (van der Werf *et al.* 2009). While the effect of anthropogenic tropical deforestation on carbon dioxide emissions and climate change has been intensively studied in recent years and is recognized as a global issue (Bonan 2008; van der Werf *et al.* 2009; Vieilledent, Grinand & Vaudry 2013b), the effect of climate change on tropical forest carbon storage, leading to a carbon-cycle feedback, remains largely uncertain (Sitch *et al.* 2008; IPCC, 2014).

A major part of the scientific studies dealing with this potential carbon-cycle feedback in tropical forest have used dynamic global vegetation models (DGVMs) coupled to global climate models (GCMs). DGVMs are process-based models which focus on the physiological response of vegetation (through photosynthesis and respiration) to increasing atmospheric CO₂ concentration and changes in temperature and precipitation (Prentice *et al.* 2007). DGVMs generally agree that net primary productivity and carbon storage on land will increase as a result of the simultaneous enhancement of plant photosynthesis and water-use efficiency under higher atmospheric CO₂ concentrations, but will decrease due to higher plant respiration rates associated with warming temperatures (Cox *et al.* 2013). Despite the numerous efforts made to improve DGVMs, large uncertainties remain in the predictions (Cramer *et al.* 2004; Quillet, Peng & Garneau 2010; Adams *et al.* 2013; Scheiter, Langan & Higgins 2013; IPCC, 2014). For instance, Cox *et al.* (2013) reported a range of 330 PgC in the projected change in the amount of carbon stored on tropical land by 2100 and Sitch *et al.* (2008) reported that cumulative land uptake differs by 494 PgC among DGVMs over the 21st century, which corresponds to 50 years of anthropogenic emissions at current level. In the past, DGVMs have either predicted a dieback of tropical forests (Cox *et al.* 2000; Sitch *et al.* 2008), with, for example, a decrease of 30% (from 568 PgC in 2000 to 398 PgC in 2100) of the carbon stored on land under the IPCC (Intergovernmental Panel on Climate Change) business-as-usual scenario IS92a (Cox *et al.* 2000) or a resilience of tropical forests to climate change (Sitch *et al.* 2008; Huntingford *et al.* 2013), with, for example, an average increase of 18% (from 165 Mg ha⁻¹ in 1980 to 195 Mg ha⁻¹ in 2100) of the African tropical forest carbon stock under IPCC business-as-usual scenario SRES A2 (Huntingford *et al.* 2013). In a study testing five DGVMs predictions of carbon fluxes using measurements of Amazon forests subjected to experimental drought, Powell *et al.* (2013) showed that the majority of models (four out of five) predicted negligible reductions in above-ground biomass in response to drought, which was in contrast to an observed c.

20% reduction in forest. Most of the uncertainty around DGVMs predictions is associated with the uncertain response of terrestrial vegetation to climate, that is to drought and heat stress (Sitch *et al.* 2008; Cox *et al.* 2013). DGVMs typically use a limited number of generic plant functional types (PFTs) to describe vegetation. This number is usually low to facilitate model parametrization, but consequently, PFTs might not be representative of the high diversity of tree species and functioning that can be found in the world tropical dry and moist forests (Powell *et al.* 2013; Schimel *et al.* 2015). Improving DGVMs is a difficult task limited by the complexity of the physiological and ecological processes explaining vegetation dynamics (Quillet, Peng & Garneau 2010; Scheiter, Langan & Higgins 2013) and by the limited amount of biological data available for model parametrization (Adams *et al.* 2013; IPCC, 2014). The question of knowing whether tropical forests are likely to compensate for anthropogenic carbon dioxide emissions through a strong positive biomass response to climate change thus remains unanswered.

In contrast to process-based approaches, simpler correlative methods could offer rapid and robust alternatives for the projection of the effects of climate change on tropical forest carbon storage. Despite known limitations (including the fact that they usually do not take into account biotic interactions, species adaptation and dispersal ability, see Pearson & Dawson (2003)), bioclimatic envelope models have been widely used to project the effect of climate change on biodiversity at both the species (Guisan & Zimmermann 2000; Thuiller *et al.* 2005; Vieilledent *et al.* 2013a) and biome level (Hannah *et al.* 2008; Zelazowski *et al.* 2011). For instance, Zelazowski *et al.* (2011) predicted a forest retreat in Amazonia, Central America and parts of Africa, and expansion in other regions, in particular around the Congo Basin. If one of the biological mechanisms explaining the impact of climate change on forest carbon stocks is the direct effect of climate on tree species metabolic rates and forest net primary productivity (Huxman *et al.* 2004; Cox *et al.* 2013), another mechanism that has to be considered on a larger time scale is the shift in tree species relative abundance and tree species range associated with climate change (Iverson & Prasad 1998; Feeley *et al.* 2011). Climate change should variably impact tree species through growth (Ouedraogo *et al.* 2013; Wagner *et al.* 2014), recruitment (Clark *et al.* 2011) and mortality (Allen *et al.* 2010; Anderegg, Kane & Anderegg 2013) with consequences on tree species' relative abundances in the community. Tree species are characterized by functional traits (Violle *et al.* 2007) such as wood density (Chave *et al.* 2009; Vieilledent *et al.* 2012) and tree stature which includes tree maximal height and maximal diameter (King, Davies & Noor 2006; Poorter, Bongers & Bongers 2006; Barthelemy & Caraglio 2007). Because these traits determine tree and forest biomass (Baker *et al.* 2004; Vieilledent *et al.* 2012; Chave *et al.* 2014), the predicted shift in species range (Hannah *et al.* 2008) and species relative abundance (Feeley *et al.* 2011) with climate change should significantly impact forest carbon storage. Interestingly, in a study simulating potential tree species extinction scenarios in a Panamanian tropical forest, Bunker

et al. (2005) underlined the fact that future carbon storage in tropical forests will be influenced strongly by future tree species composition. In their study, they simulated 18 possible extinction scenarios and showed that the loss of large-statured tree species (replaced by smaller-statured tree species) in a Panamanian forest would lead to a 29% decrease in the total forest carbon stock.

Although it is common to predict future species range using bioclimatic envelope models and climatic projections (Guisan & Zimmermann 2000; Pearson & Dawson 2003; Thuiller *et al.* 2005; Vieilledent *et al.* 2013a), it is difficult to predict changes in tree species composition and forest structure (tree height and diameter distribution), and thus forest carbon stocks, following climate change. Nonetheless, it is still possible to directly correlate forest biomass to climate. Recent empirical studies in tropical forests have shown the importance of climatic variables in determining tree stature and biomass (Feldpausch *et al.* 2011; Banin *et al.* 2012; Vieilledent *et al.* 2012; Chave *et al.* 2014) having consequences on carbon stocks at the forest stand level (Feldpausch *et al.* 2012). In particular, in a global study where 4004 trees from 58 tropical forest sites were harvested and measured, Chave *et al.* (2014) found that asymptotic tree height decreased with bioclimatic stress, that is with temperature and precipitation variability and drought intensity. Similarly, using a theoretical model based on scaling laws and energy budgets constrained by local resource limitations, Kempes *et al.* (2011) have demonstrated that maximal tree height increased with precipitation and decreased with temperature. Additional studies have shown that tree maximal size was highly correlated to forest biomass locally (Stegen *et al.* 2011; Michaletz *et al.* 2014). As a consequence, the climate should also have an effect at the ecosystem scale for determining forest carbon stocks. Only a few studies have investigated the link between climate and forest carbon stocks at the ecosystem scale using empirical correlative approaches (Keith, Mackey & Lindenmayer 2009; Stegen *et al.* 2011). Mixing data from boreal, temperate and tropical forests, the two studies by Keith, Mackey & Lindenmayer (2009) and Stegen *et al.* (2011) suggested that the role of climate was not consistent across forest types. As a result, they made no general predictions concerning changes in forest carbon stocks in response to changes in climate. Moreover, correlative models used to derive forest carbon maps at the global scale (Saatchi *et al.* 2011; Baccini *et al.* 2012) do not include explicative climatic variables and therefore cannot be used to predict future tropical forest carbon stocks under the effects of climate change.

In this study, we present the first attempt to project the effects of climate change on tropical forest carbon storage using correlative bioclimatic envelope models. To do so, we used a very large number of forest plots (1771) dispersed across Madagascar. Madagascar has a wide variety of climates and forest types and is thus particularly interesting for the study of the relationship between climate and tropical forest carbon stocks. The large climatic gradient on the island is associated with elevation and position relative to the dominant south-eastern winds (Goodman & Benstead 2003; Tadross

et al. 2008) and contributes to define a large range of tropical forest types, from spiny dry forests in the subdesert Southern regions to cloud forests which are found at the top of the northern and eastern mountains. Using this large data set, we first modelled the relationship between climate and forest carbon storage and tested for a correlation between the two. We then used this correlative model to project the future national forest carbon stock under climate change and quantify the effect of climate change on the forest carbon storage. Lastly, we compared the effect of climate change to the effect of anthropogenic tropical deforestation in terms of carbon emissions and discuss the generalization of our results to other tropical regions.

Materials and methods

COMPILING FOREST INVENTORY DATA

We assembled data from nine forest inventories carried out over the period 1996–2013 [Table 1 and Vieilledent *et al.* (2016)]. Collaboration with different institutions (governmental institutions, conservation NGOs, research institutes) allowed us to obtain a large number of forest plots (1771) in the three forest ecoregions of Madagascar (moist, dry and spiny forest ecoregions, see Fig. 1). Ecoregions were defined on the basis of climatic and vegetation criteria using the climate classification by Cornet (1974) and the vegetation classification from the 1996 IEFN national forest inventory (Ministère de l'Environnement, 1996). For each of the forest plots, tree diameter was measured at 1.30 m (D in cm) using a metre tape and identified to the genus from vernacular names. Several trees were also measured in height (H in m) using either a clinometer (coupled to a transect tape to measure distance to tree) or an ultrasonic Vertex hypsometer. For all inventories with the exception of the IEFN inventory, all trees over 5 cm D were measured in concentric circular plots of variable radius depending on tree size. The largest radius was 30 m in moist forest (plot size of 0.28 ha) and 20 m in dry or spiny forest (plot size of 0.13 ha). The IEFN inventory (the largest inventory in the data set, providing 768 plots) used concentric circular plots for trees with $5 \leq D < 15$ cm but angle count plots (Bitterlich plots) for trees with $D \geq 15$ cm, with a basal area factor of 9 and $4 \text{ m}^2 \text{ ha}^{-1}$ for moist and spiny/dry forest, respectively.

COMPUTING TREE BIOMASS WITH PANTROPICAL ALLOMETRIC MODELS

We computed the above-ground biomass (AGB_i , in Mg) of each tree i using the pantropical biomass allometric equation developed by Chave *et al.* (2014): $AGB_i = 0.0673 \times (\rho_i D_i^2 H_i)^{0.976}$, ρ_i being the tree wood density (in g cm^{-3}). When tree height was not available, we used height–diameter allometric models based on tree height and diameter measurements from the forest inventories and one destructive study (Vieilledent *et al.* 2012). We used a power relationship between H and D : $\log(H_i) = \beta_0 + \beta_1 \log(D_i) + \varepsilon_i$, $\varepsilon_i \sim \text{Normal}(0, \sigma^2)$, and we fitted the model independently for the three forest types. We obtained three significantly different height–diameter allometric models, representative of the climatic and soil conditions of each ecoregion (Fig. S1). For a given diameter, trees are on average higher in the moist forest than in the dry and spiny forests. When assigning wood density to each tree, we used the following rules: (i) if the tree genus was present in one of the Malagasy wood-density data bases

Table 1. Forest inventories used in the analysis. We combined nine forest plot inventories with above-ground carbon density data. Data were collected between year 1996 and 2013 in the three types of forest in Madagascar (moist, dry and spiny forest). Eight institutions have collaborated to provide a total of 1771 plots spread over all Madagascar

Id	Name	Date	Ecoregion	Plot nb.	Institution
1	IEFN	1996	moist, dry and spiny	768	DGF
2	JariAla	2007	moist and dry	439	DGF/USAID
3	PHCF	2010	moist and spiny	92	Goodplanet/WWF
4	CAZ-COFAV	2009	moist	117	CI
5	Makira	2010	moist	130	WCS
6	CI-forêt sèche	2011	dry	126	CI
7	Ranobe-PK32	2012	dry and spiny	14	WWF/Cirad
8	Kirindy	2012	dry	15	ONE/DGF
9	Itasy	2013	moist	70	ONE/DGF
Total				1771	

(Rakotovo et al. 2011; Vieilledent et al. 2012), we computed the mean wood density at the genus level from these sources, (ii) if the tree genus was not present in the Malagasy data bases, we computed the mean wood density at the genus level from the global wood density data base (Chave et al. 2009), and (iii) if the tree genus was not present in the Malagasy or global wood density data bases or was undetermined (this was the case for 32% of the trees), we computed the mean wood density at the plot level using wood density values of all the trees in the plot whose genus was present in the data bases. Taking into account tree size and forest plot structure (radius for circular plots and basal area factor for Bitterlich plots), we converted each tree biomass AGB_i to a value of AGB per hectare. We summed these values for all trees ≥ 5 cm DBH at the plot level and obtained the $AGB_{\geq 5,j}$ (in Mg ha^{-1}) for each forest plot j . We obtained the above-ground carbon density $ACD_{\geq 5,j}$ (in Mg ha^{-1}) for each plot j assuming a carbon ratio of 0.47: $ACD_{\geq 5,j} = 0.47 \times AGB_{\geq 5,j}$.

SPATIAL ACD MODELLING FROM VEGETATION INDEXES, TOPOGRAPHY AND CLIMATE USING THE RANDOM FORESTS ALGORITHM

We modelled ACD spatially using three types of explicative variables: vegetation indices, topography and climatic variables. Vegetation indices were obtained from 250 m resolution MODIS (Moderate Resolution Imaging Spectroradiometer) satellite images from the years 2000 to 2010. We also utilized the annual vegetation continuous field per cent tree cover (VCF in %) available from the global land cover facility (DiMiceli et al. 2011). The per cent tree cover describes the percentage of a pixel which is covered by tree canopy. Lastly, we computed the mean annual enhanced vegetation index (EVI, from 0 to 1) from 16-day MODIS MOD13Q1 data (NASA-LP DAAC, 2014). Compared to the standard Normalized Difference Vegetation Index (NDVI), which is chlorophyll sensitive, the EVI is more responsive to canopy structural variations, including leaf area index, canopy type, plant physiognomy and canopy architecture. Moreover, EVI has an improved sensitivity in high biomass regions. Because forest plot inventory data were collected on different dates (from 1996 to 2013), we associated the measured $ACD_{\geq 5,j}$ for plot j with the mean of the three annual values of EVI and VCF at the closest

years, denoted EVI_j and VCF_j . For examples, for plots sampled before 2002, we computed the mean EVI and VCF of years 2000, 2001 and 2002. For plots measured after 2008, we computed the mean EVI and VCF of years 2008, 2009 and 2010. For plots measured at years y between 2002 and 2008, we computed the mean EVI and VCF of years $y - 1$, y and $y + 1$. Using average values of EVI and VCF, we reduced the temporal noise associated with the year-to-year and seasonal variability of these indices. For the topography, we only used the elevation (E_j , in m) which was extracted from the 90 m resolution SRTM (Shuttle Radar Topography Mission) global elevation data set. Current (1950–2000) climatic data at 30 s (~1 km) resolution were obtained from the MadaClim website (<http://madaclim.org>) which provides WorldClim current climate data (Hijmans et al. 2005) specifically for Madagascar. For each plot j , we extracted the annual precipitation (P_j , in mm), the mean annual temperature (T_j , in °C) and the temperature seasonality (S_j , standard deviation of monthly temperature $\times 100$).

We used the Random Forests algorithm to model ACD_j as a function of the vegetation, the elevation and the climate: $ACD_{\geq 5,j} = f(VCF_j, EVI_j, E_j, P_j, T_j, S_j)$. Random Forests is an ensemble learning method based on decision trees (Breiman 2001). Because it uses a nonparametric approach, Random Forests accommodates strong non-linear relationships between the explicative variables and the response variable. Random Forests has been successfully used in previous scientific studies that modelled forest carbon stocks (Baccini et al. 2012; Mascaro et al. 2014). For our study, we performed the statistical analysis using the randomForest package (Liaw & Wiener 2002) available with the R software (R Development Core Team, 2014).

EVALUATING MODEL PERFORMANCE AND VARIABLE IMPORTANCE

To evaluate model performance, we repeated a cross-validation procedure ten times. About 70% of the data were selected at random to be used as training data to fit the model. The remaining 30% was used as test data to compute several model performance indices. First, we computed the coefficient of determination (R^2 , in %) which indicates the part of the observed ACD variability explained by the model. Secondly, we computed the root-mean-square error (RMSE, in Mg ha^{-1}) which measures the average difference between values predicted by the model and observations. Thirdly, we computed the mean bias (B , in %) indicating an average over- or underestimation of ACD values by the model. We computed the mean and standard deviation of the ten values obtained for the performance indices through the repeated cross-validation procedure. We also investigated the relative importance of each variable in determining ACD by computing the percentage increase in the mean standard error when the variable was randomly permuted (%IncMSE) and observing the graphical relationship between variables and ACD using partial dependence plots (see randomForest package manual for details).

DERIVING A 2010 FOREST CARBON MAP

We resampled the explicative variables data at 250 m resolution and used EVI and VCF from 2010 to derive a national carbon map at 250 m resolution from our ACD model. Because our data set included values of ACD observed only in forest habitat (and not in cropland or savanna for example), we made the assumption that our carbon map was not valid in non-forested regions. We thus masked the carbon map with a map depicting Madagascar's forest in 2010. This forest map was derived from the 30 m resolution 2000 forest map by Harper

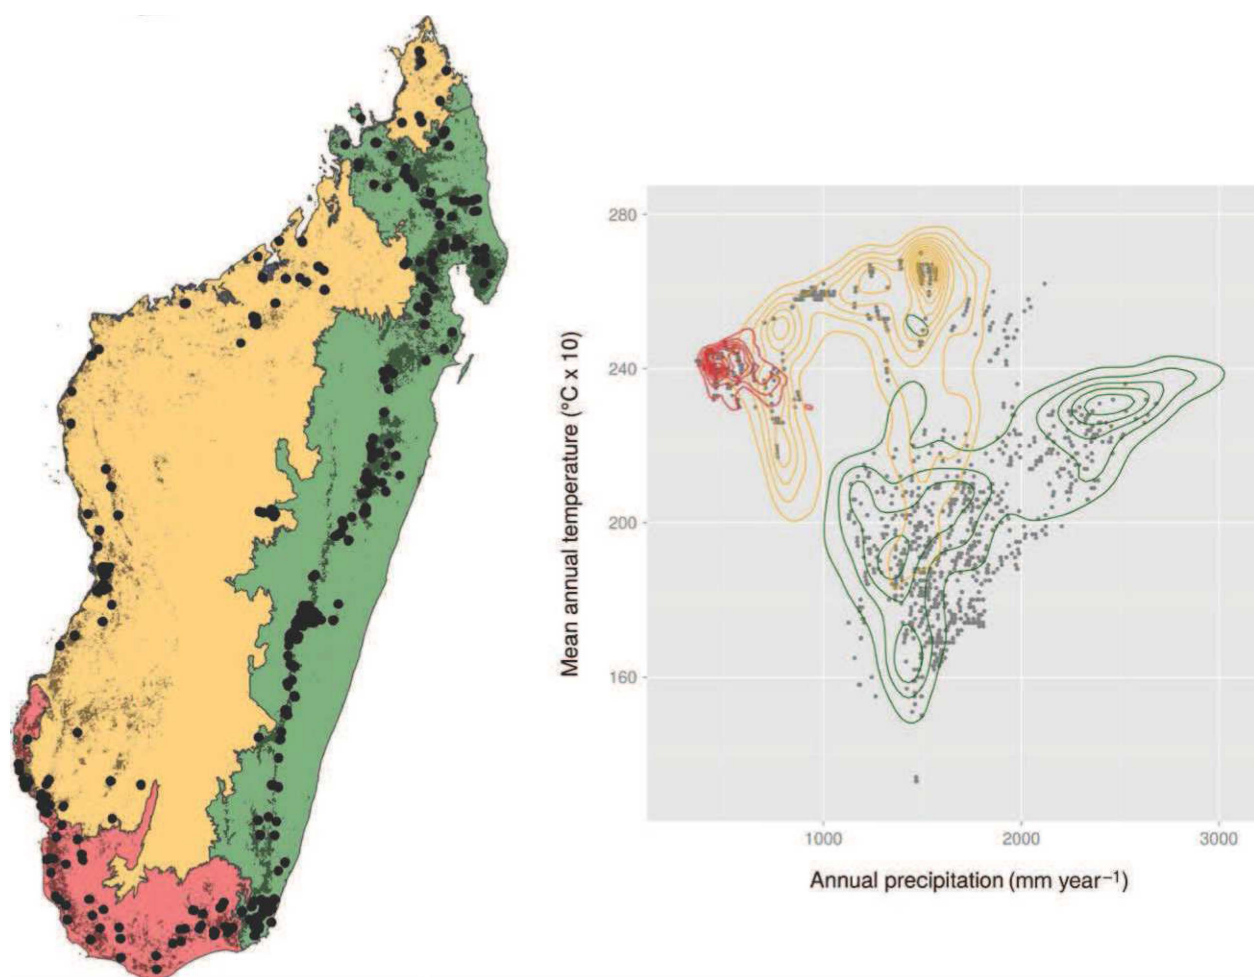


Fig. 1. Climatic ecoregions and location of forest plots. Left panel: Madagascar can be divided into three climatic ecoregions with three forest types: the moist forest in the East (green), the dry forest in the West (orange) and the spiny forest in the South (red). Ecoregions were defined following climatic (Cornet 1974) and vegetation (Ministère de l'Environnement, 1996) criteria. The 1771 forest plots of our study (black points) cover as much as possible the remaining tropical forest in 2010 (dark grey areas). Right panel: climate in the three forest types of Madagascar can be represented by 2D densities (coloured curves) obtained from sampling at random twenty thousand points in each forest type. The three forest types are characterized by significantly different climatic conditions and a large gradient of precipitation and temperature is observed. The 1771 forest plots of our study (dark grey points) are representative of the climatic conditions found in Madagascar forests.

et al. (2007). On Harper's map, ~200 000 ha clouds are present over the ~4.2 million ha moist forest ecoregion (4.8% of clouds). To remove these clouds, we used the 2000 cloud-free tree per cent cover map provided by Hansen *et al.* (2013) (also at 30 m resolution) and we chose a threshold of 75% of tree cover to decide whether to replace cloud pixels with forest or non-forest pixels (Achard *et al.* 2014). We thus obtained a cloud-free year 2000 forest map for Madagascar. From this map, using deforestation data from 2000 to 2010 by Hansen *et al.* (2013), we obtained a cloud-free forest map in 2010 at 30 m resolution. We resampled this forest map to 250 m resolution using the nearest-neighbour method. Combining the carbon map and the forest map, we obtained a forest carbon map in 2010 for Madagascar at 250 m resolution. We compared the predictions of our carbon map at 250 m resolution with the measured ACD data from the 1771 forest inventories and computed the resulting R^2 and RMSE.

COMPARISONS WITH GLOBAL CARBON MAPS

We tested whether our 2010 forest carbon map for Madagascar at 250 m was more accurate than the two global carbon maps provided

by Saatchi *et al.* (2011) and Baccini *et al.* (2012). Saatchi's map is at 1 km resolution and Baccini's map is at 500 m resolution. To allow a fair comparison between the predictions of the three maps at different resolutions, we resampled the three maps to 1 km resolution using a bilinear interpolation. We compared the predictions of the three maps with the measured ACD data, and we computed the resulting R^2 and RMSE. At the regional scale, we also compared the mean and standard deviation of the predicted ACD values by forest type using our map at 250 m, Saatchi's map at 1 km and Baccini's map at 500 m. We also compared the values of total forest carbon stock at the national scale using the three maps.

FORECASTING THE EFFECTS OF CLIMATE CHANGE ON FOREST CARBON STORAGE

We used the correlative bioclimatic envelop model we fitted previously (see Section 'Spatial ACD modelling from vegetation indexes, topography and climate using the Random Forests algorithm') to predict the potential future forest carbon stocks at 250 m for Madagascar in 2050 and 2080 considering climate change. Because changes due

to climatic variables were our key focus, we assumed no land-use change (no deforestation) between 2010 and 2080. Also, we assumed no change in the values of the vegetation indices in the future. As a consequence, our predictions only indicate the marginal effect of the climatic change on forest carbon stocks through changes in the values of the climatic variables.

For future climatic data in 2050 and 2080, we used the projections of seven global climate models (GCMs), following the representative concentration pathways (RCPs) 4.5 and 8.5. GCMs were obtained from the Coupled Model Intercomparison Project Phase 5 (CMIP5) of the Intergovernmental Panel on Climate Change (IPCC). We used the following seven GCMs: ACCESS 1.0, CCSM4, GISS-E2-R, HadGEM2-ES, IPSL-CM5ALR, MIROC5 and NorESM1-M. Climatic data were obtained from the MadaClim website (<http://madaclim.org>) which provides the CCAFS GCM future climate data (<http://www.ccafs-climate.org/data/>) specifically for Madagascar. We then compared these changes in forest carbon stock induced by climate change to carbon emissions that would be associated with a spatially homogeneous deforestation rate of $0.5\% \text{ y}^{-1}$. This value corresponds to the last estimate (period 2000–2010) of the national deforestation rate for Madagascar (Hansen *et al.* 2013; ONE *et al.*, 2013).

Results

SPATIAL DISTRIBUTION OF FOREST CARBON STOCKS IN MADAGASCAR

We obtained very coherent spatial patterns of forest carbon stocks at the national scale for Madagascar. In particular, we were able to clearly differentiate the carbon stocks for the spiny, dry and moist forests (Fig. 2) for which we obtained mean carbon stocks of $17 (\pm 6)$, $52 (\pm 25)$ and $150 (\pm 33) \text{ Mg ha}^{-1}$, respectively (Table 2). The highest carbon stocks for Madagascar ($> 200 \text{ Mg ha}^{-1}$) were found in the Makira and Masoala peninsula forests around the Antongila bay in north-east Madagascar (Fig. 2). These hilly forests are known to form the largest tracts of intact moist forest remaining in Madagascar. For the 250 m map (with spatial grid cells of 6.25 ha), the maximal predicted value of the forest carbon stock was 261 Mg ha^{-1} , which is realistic for Madagascar forests at this resolution. In comparison, the maximal carbon stock measured on much smaller forest plots ($< 0.3 \text{ ha}$) was of 348 Mg ha^{-1} . Moreover, the effect of climatic and altitudinal gradients on the forest carbon stocks was clearly visible on the forest carbon map (Fig. 2). In particular, we were able to observe a rapid drop of the forest carbon stock in the extreme south of Madagascar which corresponds to the rapid transition from the eastern moist forest receiving high precipitation to the southern xeric spiny forest in the mountains' rain shadow (Fig. 2).

Also, we were able to find much higher carbon stocks in the Amber Mountain (850 to 1475 m of altitude) at the extreme north of Madagascar, where forests benefit of a microclimate with high precipitation in the middle of the dry ecoregion.

MODEL PERFORMANCE AND VARIABLE IMPORTANCE

The cross-validation results indicated that the model had good predictive abilities with a relatively high coefficient of

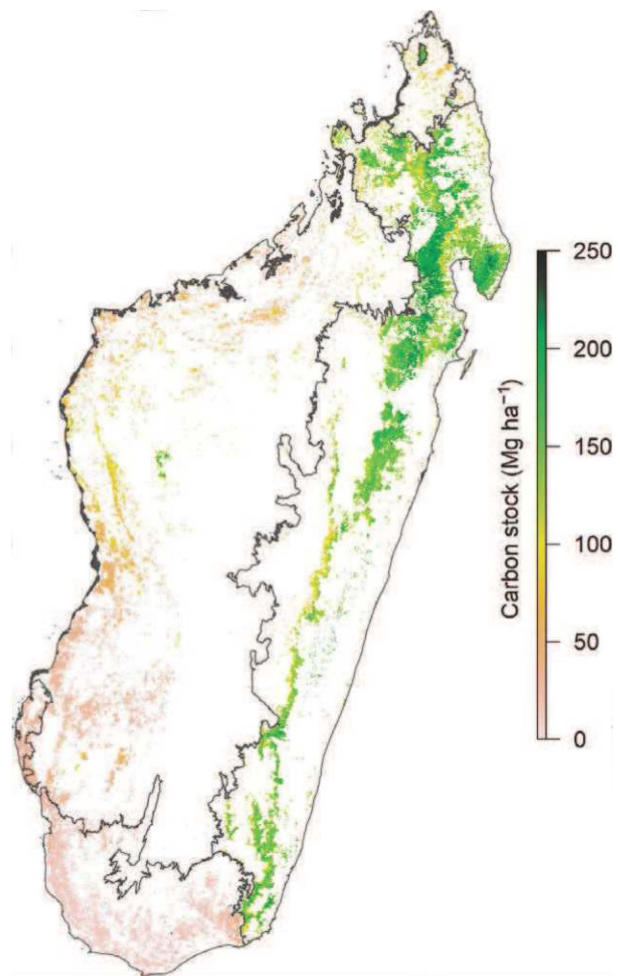


Fig. 2. Relationships between explicative variables and ACD. Graphics shows the marginal effect of the variable on ACD. Range of predicted ACD is reduced compared to the observed range of ACD in forest plots because variables other than the target variable are set to their mean values. Hash marks at the bottom of the plot indicate the deciles of the explicative variable. Percentage in the top-left or top-right corner of each panel is the percentage of increase in mean square error when the variable was randomly permuted, which indicates the variable relative importance in determining ACD.

determination ($R^2 = 64(\pm 2)\%$), and relatively low root-mean-square error and bias [$\text{RMSE} = 44(\pm 2) \text{ Mg ha}^{-1}$ and $B = +31(\pm 4)\%$]. In terms of explicative importance, variables were classified in the following decreasing order: temperature seasonality (S , 68% of increase in the mean square error when the variable was randomly permuted), precipitation (P , 49%), mean annual temperature (T , 48%), elevation (45%), EVI (40%) and VCF (38%). All variables were highly explicative of the amount of forest carbon stock, but climatic variables (temperature seasonality, annual precipitations and mean annual temperature) were found to be the most important, relative to elevation and vegetation indices. Analysing the relationship between explicative variables and ACD, we observed biologically coherent patterns (Fig. 3). ACD was higher at intermediate elevation (500–1200 m) and increased almost linearly with EVI and VCF . Regarding climatic variables,

Table 2. Comparing observed and predicted mean ACD (Mg ha^{-1}) by forest type with global carbon maps. Forest areas in 2010 are in thousands of ha and mean carbon stocks are in Mg ha^{-1} . Numbers in parentheses represent the standard deviations. Column 'Mean obs.' gives observed mean carbon stocks from forest plot inventories and column 'Mean 250 m' gives predicted mean carbon stocks from the national forest carbon map at 250 m. While global carbon maps gave relatively good estimates of the mean carbon stocks for the moist forest in Madagascar, they failed at providing good estimates and differentiating clearly the carbon stocks in the dry and spiny forests

Ecoregion	Forest area	Plot nb.	Mean obs.	Mean 250 m	Saatchi 1 km	Baccini 500 m
Moist	4625	1190	136 (67)	150 (33)	128 (53)	113 (36)
Dry	2725	367	51 (33)	52 (25)	41 (21)	33 (20)
Spiny	1741	214	18 (11)	17 (6)	34 (19)	22 (9)

ACD decreased dramatically with increasingly stressful climatic conditions. We identified the climatic tipping points beyond which the ACD dropped: for $T > 21^\circ\text{C}$, $S > 2100$ and $P < 1100 \text{ mm y}^{-1}$ (Fig. 3).

COMPARISON WITH GLOBAL CARBON MAPS

At 1 km resolution, our map provided much more accurate predictions of ACD values ($R^2 = 0.64$, $\text{RMSE} = 44 \text{ Mg ha}^{-1}$) than Saatchi's or Baccini's maps ($R^2 = 0.26$, $\text{RMSE} = 64 \text{ Mg ha}^{-1}$ and $R^2 = 0.17$, $\text{RMSE} = 63 \text{ Mg ha}^{-1}$, respectively). The best predictions were obtained using our model at 250 m resolution ($R^2 = 0.70$, $\text{RMSE} = 40 \text{ Mg ha}^{-1}$) (Fig. S2). At the forest type level (Table 2), the global carbon maps gave relatively good estimates of the mean carbon stocks for the moist forest in Madagascar, but conversely, they failed to provide good estimates and differentiate clearly between the dry and spiny forests in terms of carbon stocks. Using our map at 250 m (Fig. 2), we estimated Madagascar's total forest carbon stock to be 873086 Gg ($1\text{Gg} = 10^9 \text{ g}$) in 2010. Computing the total forest carbon stock using mean ACD estimates by forest type from Saatchi's and Baccini's maps (Table 2) led to lower estimations of the total carbon stock for Madagascar c. 2010 (764168 (−12%) and 652896 (−25%) Gg, respectively).

POTENTIAL IMPACT OF CLIMATE CHANGE ON CARBON EMISSIONS

Comparing the current climate in Madagascar with the projected climate in 2080 following RCP 8.5, temperature seasonality and mean annual temperature are predicted to increase (of $+138 \text{ SD} \times 100$ and $+3.7^\circ\text{C}$ on average, respectively), while precipitation is predicted to decrease (of -107 mm y^{-1} on average) over almost the entire forest area (Fig. S3). Using climatic projections following the RCP 8.5 and our forest carbon stock model, we forecasted the changes in forest carbon stocks by the year 2080 (Fig. 4). Most of Madagascar forests are likely to experience a decrease of their carbon stock, up to -150 Mg ha^{-1} on the period 2010–2080 for the Madagascar moist forest. In some areas, in particular in the spiny forest, a limited increase of the carbon stock is expected ($< 50 \text{ Mg ha}^{-1}$). The increase of the forest carbon stock is associated with the predicted future increase of the precipitation in these areas (Fig. S3). At the national scale,

these changes should lead to an average forest carbon stock loss of 17% (range: 7–24%) by the year 2080 (Fig. 4 and Table S1). Following RCP 4-5, the forest carbon stock loss ranged from 2 to 13% (Table S1). Following RCP 8-5, the total forest carbon stock would drop progressively from 873086 Gg in 2010, to 799 097 Gg (−8%) in 2050 and 720944 Gg (−17%) in 2080 (Fig. 4). For a comparison, a spatially homogeneous deforestation of $0.5\% \text{ y}^{-1}$ from 2010 to 2080 over Madagascar would lead to a residual carbon stock of 614714 Gg (−30%).

Discussion

AN ACCURATE FOREST CARBON MAP FOR MADAGASCAR

Using a large data set including 1771 forest plots spread across the entire country and representative of the three tropical forest types existing in Madagascar, we were able to fit a good predictive model ($R^2 = 64\%$, $\text{RMSE} = 44 \text{ Mg ha}^{-1}$ and $B = +31\%$). We obtained an accurate ($R^2 = 0.70$, $\text{RMSE} = 40 \text{ Mg ha}^{-1}$) national forest carbon map at 250 m resolution for Madagascar for year 2010. In a study mapping forest carbon on 16 million hectares in the Western Amazon and using a more sophisticated model with spatial autocorrelation, Mascaro *et al.* (2014) obtained a map with a lower R^2 ($R^2 = 59\%$) but a smaller RMSE ($\text{RMSE} = 26 \text{ Mg ha}^{-1}$). In their case, the initial variability of observed ACD was limited as they used 1 km LiDAR-based estimates (and not estimates at a point), thus potentially reducing the residual values between predicted and observed ACD. Regarding forest carbon maps that can be used at the national scale for Madagascar, the two global maps by Saatchi *et al.* (2011) and Baccini *et al.* (2012) have a coarser resolution (500 m and 1 km resolution). We showed that these two global maps were less accurate than the map we obtained at 250 m resolution ($R^2 \leq 26$ and $\text{RMSE} \geq 63 \text{ Mg ha}^{-1}$) and that they failed to differentiate clearly between the carbon stocks in the spiny and dry forests of Madagascar. When used at the national level, the two global maps underestimated (by more than 12%) the total carbon stock of Madagascar, in comparison with the map produced herein. The lower accuracy of the global carbon maps can be explained by two factors. First, only Saatchi's map (which is the most accurate of the two maps according to our study) utilized forest plot data from

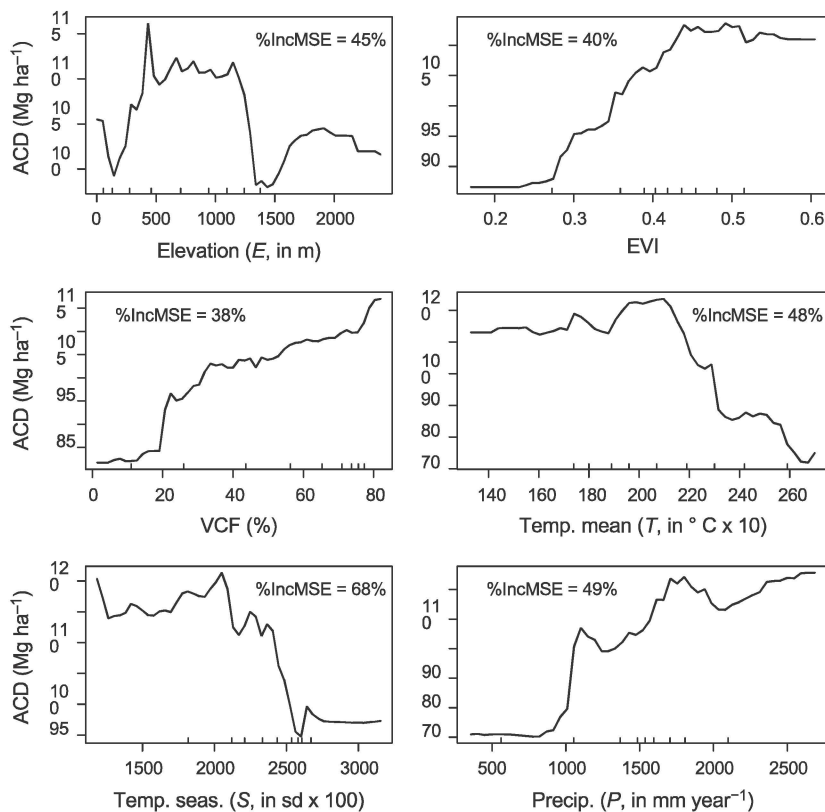


Fig. 3. Forest carbon map in 2010 for Madagascar. We derived a national forest carbon map in 2010 for Madagascar at 250 m resolution. We fitted our model using above-ground carbon density for 1771 forest plots measured between 1996 and 2013. Our model included six explicative variables: two vegetation indexes (VCF and EVI from 2000–2010 MODIS satellite images at 250 m), one topographic variable (elevation from SRTM at 90 m) and three climatic variables [mean annual temperature, mean annual precipitation and temperature seasonality from WorldClim at 30 arc-seconds (~ 1 km)]. Our predictions are limited to the extent of the forest in 2010. Clear differences appear for the forest carbon stocks between the three ecoregions including moist, dry and spiny forest (see black lines for delimitations).

Madagascar (202 plots) to calibrate the statistical models used to predict ACD. Regarding the lack of distinction between spiny and dry forest carbon stocks, the plots used to calibrate Saatchi's model were located in the moist forest and were thus not representative of Madagascar's other forest types. The fact that a substantial number of carefully established field plots are necessary to derive accurate ACD maps has been previously underlined by Mitchard *et al.* (2014). Secondly, neither Baccini's nor Saatchi's maps included climatic variables as explicative factors of ACD, while we have shown in our study that they were more important explicative variables than the altitude and the vegetation indices.

EFFECTS OF CLIMATE ON FOREST CARBON STOCKS

The tree height is a key variable determining tree biomass (Vieilledent *et al.* 2012; Chave *et al.* 2014). Recent empirical and theoretical studies have emphasized the importance of climatic variables in determining the tree height–diameter relationship (Banin *et al.* 2012; Chave *et al.* 2014; Feldpausch *et al.* 2011) and the tree maximal height (Kempes *et al.* 2011). In a pantropical study, Chave *et al.* (2014) have demonstrated that tree height decreased with increasing temperature seasonality, precipitation seasonality and climatic water deficit. Chave *et al.* (2014) have shown that temperature seasonality (a proxy for the length of the growing season) was by far the most important climatic variable in explaining the tree height–diameter relationship and consequently tree biomass. In our study, we also identified temperature seasonality as being the most important variable

determining forest biomass at the plot level (with a decrease of ACD with temperature seasonality), thus confirming the results obtained by Chave *et al.* (2014). In a theoretical study, based on scaling laws and energy budgets constrained by local resource limitations, Kempes *et al.* (2011) have demonstrated that maximal tree height increased with precipitation and decreased with temperature, thus corroborating the results of our study.

At the forest ecosystem level, Fischer *et al.* (2014) found a pattern similar to ours regarding the relationship between forest carbon stock and precipitation in the moist forests of Madagascar. The authors identified a tipping point around 2000 mm yr^{-1} for precipitation under which the forest carbon stock was rapidly decreasing. While they argued that a temporary 20% reduced rainfall would have a moderate impact on the forest carbon stock (due to the soil water content that would support tree growth), they found that a decrease of 50% of rainfall would lower the carbon stocks by about 20%. In a large-scale study using data from 271 plots from temperate and tropical forests in North, Central and South America, Stegen *et al.* (2011) found weak relationships between forest biomass and climate. No significant relationships was found between forest biomass and mean annual temperature across forest types and a weak, albeit significant, positive relationship was found between forest biomass and annual precipitation. In another study using biomass data from 136 plots from the world's most carbon-dense primary forests, Keith, Mackey & Lindenmayer (2009) concluded that the highest biomass carbon density occurs in cool, moderately wet climates in temperate moist forest biomes. However, Fig. 3 in

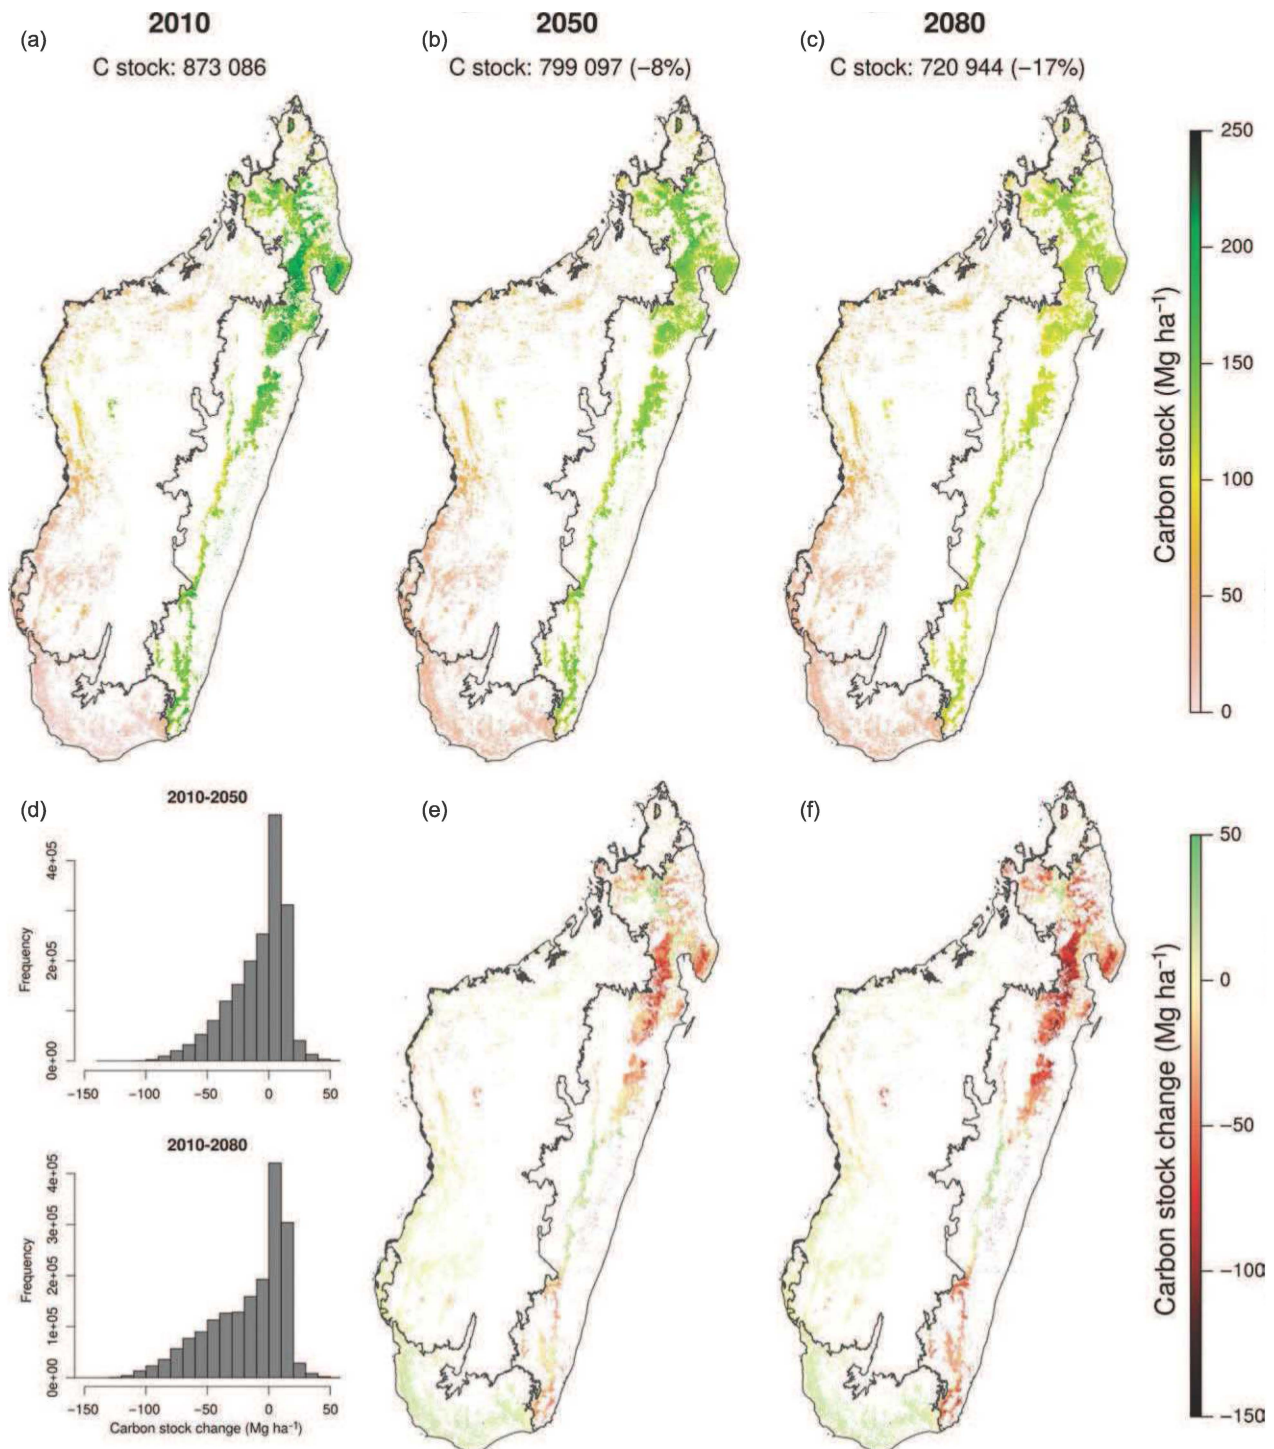


Fig. 4. Forest carbon stock evolution with climate change in Madagascar. (a–c): Maps of Madagascar forest carbon stocks for the years 2010, 2050 and 2080. Using climate projections in 2050 and 2080 (from seven IPCC CMIP5 global climate models following the RCP 8.5) and our carbon stock model, we estimated the average forest carbon stock in 2050 and 2080 for Madagascar. At the national scale, climate change would result in a progressive decrease of the total forest carbon stock (see C stocks, in Gg = 10^9 g) of -9% and -17% for years 2050 and 2080, respectively. (d): Distributions of the 250 m resolution forest pixels as a function of the carbon stock change for the periods 2010–2050 and 2010–2080. (e–f): Carbon stock change on the periods 2010–2050 and 2010–2080. Moist forest in the East should experience the greatest changes with a drastic decrease of the forest carbon stock.

Keith, Mackey & Lindenmayer (2009) and Fig. 4 in Stegen *et al.* (2011) show that for sites with a tropical climate (excluding boreal and temperate sites with mean annual

temperature $< 15^\circ\text{C}$), forests under warmer and drier climates (with higher mean annual temperature and lower annual precipitation) appear to have lower carbon stocks. Results

obtained by Keith, Mackey & Lindenmayer (2009) and Stegen *et al.* (2011) are then in line with the results obtained by Chave *et al.* (2014) regarding the relationship between tree biomass and climate in tropical forests and are also comparable with the results of our study. More work is still required in order to understand more precisely the effect of climate on forest carbon storage across other forest types such as boreal and temperate forests (Keith, Mackey & Lindenmayer 2009; Stegen *et al.* 2011; Koven 2013). One difficulty is that temperate regions have a diversity of forest types that support a wide range of mature carbon stocks or have a long land-use history with reduced carbon stocks. As a consequence, past studies comparing carbon stocks in tropical and temperate forests have led to contrasting conclusions. For example, Houghton (2005) and Saatchi *et al.* (2011) have shown that tropical forests have a much higher mean biomass (c. 130 Mg ha⁻¹) than temperate forests (c. 50 Mg ha⁻¹), which contradicts the results reported by Keith, Mackey & Lindenmayer (2009).

The results of our study at the forest ecosystem scale, together with the previous results obtained by Chave *et al.* (2014) at the tree level, are coherent with the known physiological and ecological mechanisms explaining the relationship between forest biomass and climate. Several studies have shown that climate (mainly through growing season length and water availability) directly impacts tree species metabolic rates such as respiration and photosynthesis, having direct (\sim daily or yearly) repercussions on tree species growth and forest net primary productivity (Huxman *et al.* 2004; Cox *et al.* 2013). On a larger time scale (\sim decades), climate drives tree species demographic rates such as mortality (Allen *et al.* 2010; Anderegg, Kane & Anderegg 2013) and fecundity (Clark *et al.* 2011), thus determining tree species composition and forest structure (Feeley *et al.* 2011) which in turn define forest carbon stocks (Bunker *et al.* 2005). On this point, it is interesting to see that the estimate of 29% decrease in the forest carbon stock reported by Bunker *et al.* (2005), which is associated with a replacement of large-statured tree species with smaller-statured tree species, is close to our estimate of 7–24%. At larger geographical scales and on an even larger time scales (\sim centuries), tree species composition is assumed to be the result of a selection pressure with an adaptation to local climates (Iverson & Prasad 1998; Clark & McLachlan 2003; Michaletz *et al.* 2014). Metabolic scaling theory (Michaletz *et al.* 2014) and recent empirical data (Stegen *et al.* 2011) led to the conclusion that forest biomass is strongly correlated to the size of the largest individual, which is in itself strongly dictated by tree species architectural characteristics (Poorter, Bongers & Bongers 2006; Barthelemy & Caraglio 2007) and the local climate (Feldpausch *et al.* 2011; Kempes *et al.* 2011; Banin *et al.* 2012; Vieilledent *et al.* 2012; Chave *et al.* 2014). In Madagascar, tree species composition and climatic conditions in the moist, dry and spiny forest are substantially different (Goodman & Benstead 2003; Harper *et al.* 2007) resulting in significantly different sizes for the largest individual between forest types (Fig. S1 and Vieilledent *et al.* (2012)) and in significantly different forest

carbon stocks (Fig. 2). Significant changes in tree species distribution are expected in Madagascar (Hannah *et al.* 2008; Vieilledent, Grinand & Vaudry 2013b). Tree species adapted to drier conditions and to shorter growing seasons are likely to increase their relative abundance in forest communities locally (Feeley *et al.* 2011) or to expand their geographical range (Hannah *et al.* 2008). It has been demonstrated that these tree species are usually characterized by lower asymptotic heights (Vieilledent *et al.* 2012; Chave *et al.* 2014) and lower biomass. Climate change would thus indirectly induce a decrease of the forest carbon stock through the selection of small-statured tree species.

TROPICAL FORESTS AS A CARBON SINK: COMPARING DGVMs AND BIOCLIMATIC ENVELOPE MODEL OUTPUTS

Our model estimates that, in Madagascar, changes in climatic conditions predicted to occur between 2010 and 2080 will cause the loss of 17% (range: 7–24%) of the forest carbon stock and would result in the emissions of 152142 Gg of carbon into the atmosphere. Climate change induced emissions would be of the same order of magnitude as the emissions associated with projected anthropogenic deforestation on the same period of time, with a loss of 30% of the forest carbon stock and emissions of 258372 Gg of carbon into the atmosphere. At present, most DGVMs also simulate a decrease of the vegetation carbon stock in response to reduction in precipitation and increase in temperature (Sitch *et al.* 2008; Cox *et al.* 2013; Huntingford *et al.* 2013). For example, Huntingford *et al.* (2013) estimated a decrease from 5 to 30 Mg ha⁻¹ of the vegetation carbon stock in tropical Africa between 1860 and 2100 under the effect of increasing temperature (Fig. SI2 in the cited paper). But the strong decrease of the vegetation carbon stock due to climate change would be largely compensated by the fertilization effect of CO₂ modelled in DGVMs. Accounting for both climate change and CO₂ fertilization, Huntingford *et al.* (2013) estimated an average increase of 30 Mg ha⁻¹ (+18%) of the African tropical forest carbon stock between 1980 and 2100 under IPCC business-as-usual SRES A2 scenario. Thus, most actual DGVMs predict a resilience of tropical forests to climate change due to an increase of tree growth (Sitch *et al.* 2008; Cox *et al.* 2013; Huntingford *et al.* 2013). Compared to DGVMs, our model does not include the direct effect of CO₂ fertilization on forest growth and resulting forest carbon stock. Indeed, higher CO₂ concentration is expected to raise plant photosynthetic rates and enhance water-use efficiency (Bonan 2008). However, there is no empirical evidence that these physiological responses do increase carbon sequestration in natural tropical forests (van der Sleen *et al.* 2015). For example, CO₂ fertilization might lead to an increase of tree growth but also to an increase of tree mortality due to faster growth (Brienen *et al.* 2015). Moreover, some studies showed that productivity may eventually become constrained by nutrient limitation (Norby *et al.* 2010) or climate stress (Perry *et al.* 2013). Finally, CO₂ enrichment experiments showing the CO₂ fertilization effect have been conducted in temperate forests (Norby *et al.* 2010)

but not yet in tropical forests (but see Tollefson (2013)). As a consequence, DGVMs might overestimate the sink capacity of tropical forests (van der Sleen *et al.* 2015). Although not taking into account the potential effect of CO₂ fertilization, our forest carbon model provides more insight about the vegetation response to changes in temperature and precipitation, which constitutes the largest source of variability in DGVM outputs (Sitch *et al.* 2008; Cox *et al.* 2013; Huntingford *et al.* 2013).

Our approach shares the same hypothesis as when bioclimatic envelope models are used to predict the effects of climate change on species distribution (Pearson & Dawson 2003). In particular, for the forecast of future forest carbon stocks, we assumed that tree species will be able to track climate change (full dispersal hypothesis). Also, we assumed no change in the values of the vegetation indices in the future whereas climate change should impact them. These two hypotheses are conservative regarding the main result of our study which predicts a decrease of the forest carbon stock in Madagascar with climate change. Given the velocity of climate change (Loarie *et al.* 2009) and the difficulties experienced by tree species to migrate and track climate change (Zhu, Woodall & Clark 2012), shifts in species distribution at large geographical scale are uncertain. More likely, tree species will experience range contraction (Zhu, Woodall & Clark 2012; Vieilledent, Grinand & Vaudry 2013b) and climate change could lead to widespread tree-mortality events (Anderegg, Kane & Anderegg 2013; Brien *et al.* 2015). Also, it is unlikely that vegetation indices will increase with climate change. Constant or lower values of vegetation indices due to an increase in the abundance of small-statured tree individuals and species are expected. Considering these two hypotheses, it is likely that our model underestimates the loss of forest carbon stock that would be associated with climate change.

At the global scale, climate observations and model predictions suggest continued increases in temperature (Hulme & Viner 1998) and decreases in precipitation over much of the humid tropics (Malhi & Wright 2004) thus suggesting a potential decrease in tropical tree growth and height in the future. Regarding seasonality, changes in rainfall seasonality are expected throughout the tropics (Feng, Porporato & Rodriguez-Iturbe 2013), but more research is still needed to be able to interpret these seasonal changes in terms of potential impacts on tree species size and forest carbon storage. Considering our results and those from previous studies (Bunker *et al.* 2005; Chave *et al.* 2014; van der Sleen *et al.* 2015), a substantial part of the tropical forest carbon stock is likely to be released into the atmosphere under the effect of climate change. On this basis, the recent simulated resilience of tropical forests to climate change with DGVMs, which relies mostly on the strong CO₂ fertilization effect (Sitch *et al.* 2008; Cox *et al.* 2013; Huntingford *et al.* 2013) may be questioned. The decrease of tropical forest carbon stocks with climate change, leading to a carbon-cycle feedback, should not be neglected and might be of the same order of magnitude as tropical anthropogenic deforestation regarding CO₂ emissions in the atmosphere.

Acknowledgements

Financial support was provided by Cirad, AFD (Agence Française de Développement) through the AT-REDD+ Madagascar project and FRB–FFEM (Fondation pour la Recherche sur la Biodiversité – Fond Français pour l'Environnement Mondial) through the BioSceneMada project (project agreement AAP-SCEN-2013 I). We would also like to thank all the people who contributed to the forest inventories in the field. Lastly, this work would not have been possible without the willingness of governmental officials, conservation NGOs and research institutes in Madagascar to share their forest inventory data for the establishment of a national forest carbon map. We thank them for their support.

Data accessibility

The following data are accessible on the Dryad digital repository associated with this study (see Vieilledent *et al.* (2016) and <http://dx.doi.org/10.5061/dryad.9ph68>):

- Above-ground carbon density (ACD) data.
- Present and future climatic data for Madagascar.
- Additional explicative variables (elevation, EVI and VCF) used to derive the forest carbon map.
- R script that can be used to fully reproduce the results of the study.
- Random Forests model used to derive the forest carbon maps.
- Madagascar 2010 forest carbon map at 250 m resolution.

References

- Achard, F., Beuchle, R., Mayaux, P., Stibig, H.J., Bodart, C., Brink, A. *et al.* (2014) Determination of tropical deforestation rates and related carbon losses from 1990 to 2010. *Global Change Biology*, **20**, 2540–2554.
- Adams, H.D., Williams, A.P., Xu, C., Rauscher, S.A., Jiang, X. & McDowell, N.G. (2013) Empirical and process-based approaches to climate-induced forest mortality models. *Frontiers in Plant Science*, **4**.
- Allen, C.D., Macalady, A.K., Chenchouni, H., Bachelet, D., McDowell, N., Vennetier, M. *et al.* (2010) A global overview of drought and heat-induced tree mortality reveals emerging climate change risks for forests. *Forest Ecology and Management*, **259**, 660–684.
- Anderegg, W.R., Kane, J.M. & Anderegg, L.D. (2013) Consequences of widespread tree mortality triggered by drought and temperature stress. *Nature Climate Change*, **3**, 30–36.
- Baccini, A., Goetz, S.J., Walker, W.S., Laporte, N.T., Sun, M., Sulla-Menashe, D., Hackler, J., Beck, P.S.A., Dubayah, R., Friedl, M.A., Samanta, S. & Houghton, R.A. (2012) Estimated carbon dioxide emissions from tropical deforestation improved by carbon-density maps. *Nature Climate Change*, **2**, 182–185.
- Baker, T.R., Phillips, O.L., Malhi, Y., Almeida, S., Arroyo, L., Di Fiore, A. *et al.* (2004) Variation in wood density determines spatial patterns in Amazonian forest biomass. *Global Change Biology*, **10**, 545–562.
- Banin, L., Feldpausch, T.R., Phillips, O.L., Baker, T.R., Lloyd, J., Affum-Baffoe, K. *et al.* (2012) What controls tropical forest architecture? Testing environmental, structural and floristic drivers. *Global Ecology and Biogeography*, **21**, 1179–1190.
- Barthelemy, D. & Caraglio, Y. (2007) Plant architecture: a dynamic, multilevel and comprehensive approach to plant form, structure and ontogeny. *Annals of Botany*, **99**, 375–407.
- Bonan, G.B. (2008) Forests and climate change: forcings, feedbacks, and the climate benefits of forests. *Science*, **320**, 1444–1449.
- Breiman, L. (2001) Random Forests. *Machine Learning*, **45**, 5–32.
- Brien, R., Phillips, O., Feldpausch, T., Gloor, E., Baker, T., Lloyd, J. *et al.* (2015) Long-term decline of the amazon carbon sink. *Nature*, **519**, 344–348.
- Bunker, D.E., DeClerck, F., Bradford, J.C., Colwell, R.K., Perfecto, I., Phillips, O.L., Sankaran, M. & Naeem, S. (2005) Species loss and above-ground carbon storage in a tropical forest. *Science*, **310**, 1029–1031.
- Chave, J., Coomes, D., Jansen, S., Lewis, S.L., Swenson, N.G. & Zanne, A.E. (2009) Towards a worldwide wood economics spectrum. *Ecology Letters*, **12**, 351–366.
- Chave, J., Réjou-Méchain, M., Burquez, A., Chidumayo, E., Colgan, M.S., Delitti, W.B. *et al.* (2014) Improved allometric models to estimate the

- above-ground biomass of tropical trees. *Global Change Biology*, **20**, 3177–3190.
- Clark, J.S. & McLachlan, J.S. (2003) Stability of forest biodiversity. *Nature*, **423**, 635–638.
- Clark, J.S., Bell, D.M., Hersh, M.H. & Nichols, L. (2011) Climate change vulnerability of forest biodiversity: climate and competition tracking of demographic rates. *Global Change Biology*, **17**, 1834–1849.
- Comet, A. (1974) *Essai de cartographie bioclimatique à Madagascar*. Tech. rep., Orstom, **15**, 1–13.
- Cox, P.M., Betts, R.A., Jones, C.D., Spall, S.A. & Totterdell, I.J. (2000) Acceleration of global warming due to carbon-cycle feedbacks in a coupled climate model. *Nature*, **408**, 184–187.
- Cox, P.M., Pearson, D., Booth, B.B., Friedlingstein, P., Huntingford, C., Jones, C.D. & Luke, C.M. (2013) Sensitivity of tropical carbon to climate change constrained by carbon dioxide variability. *Nature*, **494**, 341–344.
- Cramer, W., Bondeau, A., Schaphoff, S., Lucht, W., Smith, B. & Sitch, S. (2004) Tropical forests and the global carbon cycle: impacts of atmospheric carbon dioxide, climate change and rate of deforestation. *Philosophical Transactions of the Royal Society of London Series B: Biological Sciences*, **359**, 331–343.
- DiMiceli, C., Carroll, M., Sohlberg, R., Huang, C., Hansen, M. & Townshend, J. (2011) Annual global automated MODIS vegetation continuous fields (MOD44B) at 250 m spatial resolution for data years beginning day 65, 2000–2010, collection 5 percent tree cover. University of Maryland, College Park, MD, USA.
- Feeley, K.J., Davies, S.J., Perez, R., Hubbell, S.P. & Foster, R.B. (2011) Directional changes in the species composition of a tropical forest. *Ecology*, **92**, 871–882.
- Feldpausch, T., Banin, L., Phillips, O., Baker, T., Lewis, S., Quesada, C., Affum-Baffoe, K., Arets, E., Berry, N. & Bird, M. (2011) Height-diameter allometry of tropical forest trees. *Biogeosciences*, **8**, 1081–1106.
- Feldpausch, T.R., Lloyd, J., Lewis, S.L., Brien, R.J.W., Gloor, E., Monteagudo Mendoza, A. et al. (2012) Tree height integrated into pan-tropical forest biomass estimates. *Biogeosciences*, **9**, 2567–2622.
- Feng, X., Porporato, A. & Rodriguez-Iturbe, I. (2013) Changes in rainfall seasonality in the tropics. *Nature Climate Change*, **3**, 811–815.
- Fischer, R., Armstrong, A., Shugart, H.H. & Huth, A. (2014) Simulating the impacts of reduced rainfall on carbon stocks and net ecosystem exchange in a tropical forest. *Environmental Modelling & Software*, **52**, 200–206.
- Goodman, S. & Benstead, J. (2003) *The natural history of Madagascar*, p. 1709. University of Chicago Press, Chicago, IL, USA.
- Guisan, A. & Zimmermann, N.E. (2000) Predictive habitat distribution models in ecology. *Ecological Modelling*, **135**, 147–186.
- Hannah, L., Dave, R., Lowry, P.P., Andelman, S., Andrianarisata, M., Andriamaro, L. et al. (2008) Climate change adaptation for conservation in Madagascar. *Biology Letters*, **4**, 590–594.
- Hansen, M.C., Potapov, P.V., Moore, R., Hancher, M., Turubanova, S.A., Tyukavina, A. et al. (2013) High-resolution global maps of 21st-century forest cover change. *Science*, **342**, 850–853.
- Harper, G.J., Steininger, M.K., Tucker, C.J., Juhn, D. & Hawkins, F. (2007) Fifty years of deforestation and forest fragmentation in Madagascar. *Environmental Conservation*, **34**, 325–333.
- Hijmans, R.J., Cameron, S.E., Parra, J.L., Jones, P.G. & Jarvis, A. (2005) Very high resolution interpolated climate surfaces for global land areas. *International Journal of Climatology*, **25**, 1965–1978.
- Houghton, R. (2005) Above-ground forest biomass and the global carbon balance. *Global Change Biology*, **11**, 945–958.
- Hulme, M. & Viner, D. (1998) A climate change scenario for the tropics. *Potential Impacts of Climate Change on Tropical Forest Ecosystems* (ed. A. Markham) pp. 5–36. Springer, Dordrecht, The Netherlands.
- Huntingford, C., Zelazowski, P., Galbraith, D., Mercado, L.M., Sitch, S., Fisher, R. et al. (2013) Simulated resilience of tropical rainforests to CO₂-induced climate change. *Nature Geoscience*, **6**, 268–273.
- Huxman, T.E., Smith, M.D., Fay, P.A., Knapp, A.K., Shaw, M.R., Loik, M.E. et al. (2004) Convergence across biomes to a common rain-use efficiency. *Nature*, **429**, 651–654.
- IPCC (2014) *Fifth Assessment Report (AR5), Climate Change 2014: Synthesis Report*. Tech. rep., The Intergovernmental Panel on Climate Change, IPCC, Geneva, Switzerland.
- Iverson, L.R. & Prasad, A.M. (1998) Predicting abundance of 80 tree species following climate change in the eastern United States. *Ecological Monographs*, **68**, 465–485.
- Keith, H., Mackey, B.G. & Lindenmayer, D.B. (2009) Re-evaluation of forest biomass carbon stocks and lessons from the world's most carbon-dense forests. *Proceedings of the National Academy of Sciences*, **106**, 11635–11640.
- Kempes, C.P., West, G.B., Crowell, K. & Girvan, M. (2011) Predicting maximum tree heights and other traits from allometric scaling and resource limitations. *PLoS ONE*, **6**, e20551.
- King, D.A., Davies, S.J. & Noor, N.S.M. (2006) Growth and mortality are related to adult tree size in a Malaysian mixed dipterocarp forest. *Forest Ecology and Management*, **223**, 152–158.
- Koven, C.D. (2013) Boreal carbon loss due to poleward shift in low-carbon ecosystems. *Nature Geoscience*, **6**, 452–456.
- Liaw, A. & Wiener, M. (2002) Classification and Regression by randomForest. *R News*, **2**, 18–22.
- Loarie, S.R., Duffy, P.B., Hamilton, H., Asner, G.P., Field, C.B. & Ackerly, D.D. (2009) The velocity of climate change. *Nature*, **462**, 1052–1055.
- Malhi, Y. & Wright, J. (2004) Spatial patterns and recent trends in the climate of tropical rainforest regions. *Philosophical Transactions of the Royal Society of London Series B: Biological Sciences*, **359**, 311–329.
- Mascaro, J., Asner, G.P., Knapp, D.E., Kennedy-Bowdoin, T., Martin, R.E., Anderson, C., Higgins, M. & Chadwick, K.D. (2014) A tale of two “forests”: random Forest machine learning aids tropical forest carbon mapping. *PLoS ONE*, **9**, e85993.
- Michaletz, S.T., Cheng, D., Kerkhoff, A.J. & Enquist, B.J. (2014) Convergence of terrestrial plant production across global climate gradients. *Nature*, **512**, 39–43.
- Ministère de l'Environnement (1996) IEFN: Inventaire Ecologique Forestier National. Tech. rep., Ministère de l'Environnement de Madagascar, Direction des Eaux et Forêts, DFS Deutsch Forest Service GmbH, Entreprise d'études de développement rural “Mamokatra”, FTM.
- Mitchard, E.T., Feldpausch, T.R., Brien, R.J., Lopez-Gonzalez, G., Monteagudo, A., Baker, T.R. et al. (2014) Markedly divergent estimates of amazon forest carbon density from ground plots and satellites. *Global Ecology and Biogeography*, **23**, 935–946.
- NASA Land Processes Distributed Active Archive Center (LP DAAC) (2014) *MODIS MOD13Q1 Version 005*. USGS/Earth Resources Observation and Science (EROS) Center, Sioux Falls, SD, USA.
- Norby, R.J., Warren, J.M., Iversen, C.M., Medlyn, B.E. & McMurtrie, R.E. (2010) CO₂ enhancement of forest productivity constrained by limited nitrogen availability. *Proceedings of the National Academy of Sciences*, **107**, 19368–19373.
- ONE, DGF, FTM, MNP, CI (2013) *Evolution de la couverture de forêts naturelles à Madagascar 2005–2010*, Antananarivo.
- Ouédrago, D.Y., Mortier, F., Gourlet-Fleury, S., Freycon, V. & Picard, N. (2013) Slow-growing species cope best with drought: evidence from long-term measurements in a tropical semi-deciduous moist forest of Central Africa. *Journal of Ecology*, **101**, 1459–1470.
- Pan, Y., Birdsey, R.A., Fang, J., Houghton, R., Kauppi, P.E., Kurz, W.A. et al. (2011) A large and persistent carbon sink in the world's forests. *Science*, **333**, 988–993.
- Pearson, R.G. & Dawson, T.P. (2003) Predicting the impacts of climate change on the distribution of species: are bioclimate envelope models useful? *Global Ecology and Biogeography*, **12**, 361–371.
- Perry, L.G., Shafroth, P.B., Blumenthal, D.M., Morgan, J.A. & LeCain, D.R. (2013) Elevated CO₂ does not offset greater water stress predicted under climate change for native and exotic riparian plants. *New Phytologist*, **197**, 532–543.
- Poorter, L., Bongers, L. & Bongers, F. (2006) Architecture of 54 moist-forest tree species: traits, trade-offs, and functional groups. *Ecology*, **87**, 1289–1301.
- Powell, T.L., Galbraith, D.R., Christoffersen, B.O., Harper, A., Imbuzeiro, H., Rowland, L. et al. (2013) Confronting model predictions of carbon fluxes with measurements of amazon forests subjected to experimental drought. *New Phytologist*, **200**, 350–365.
- Prentice, I.C., Bondeau, A., Cramer, W., Harrison, S.P., Hickler, T., Lucht, W., Sitch, S., Smith, B. & Sykes, M.T. (2007) Dynamic global vegetation modeling: quantifying terrestrial ecosystem responses to large-scale environmental change. *Terrestrial ecosystems in a changing world* (eds J.G. Canadell, D.E. Pataki & L.F. Pitelka) pp. 175–192. Springer, Berlin, Germany.
- Quillet, A., Peng, C. & Garneau, M. (2010) Toward dynamic global vegetation models for simulating vegetation-climate interactions and feedbacks: recent developments, limitations, and future challenges. *Environmental Reviews*, **18**, 333–353.
- R Development Core Team (2014) *R: A Language and Environment for Statistical Computing*. R Foundation for Statistical Computing, Vienna, Austria. <http://www.R-project.org>.
- Rakotovo, G., Rabevoahitra, A., Gerad, J. & Collas de Chatelperron, P. (2011) *Atlas des bois de Madagascar*. Tech. rep., Fofifa and Cirad.
- Saatchi, S.S., Harris, N.L., Brown, S., Lefsky, M., Mitchard, E.T.A., Salas, W. et al. (2011) Benchmark map of forest carbon stocks in tropical regions

- across three continents. *Proceedings of the National Academy of Sciences*, **108**, 9899–9904.
- Scheiter, S., Langan, L. & Higgins, S.I. (2013) Next-generation dynamic global vegetation models: learning from community ecology. *New Phytologist*, **198**, 957–969.
- Schimel, D., Pavlick, R., Fisher, J.B., Asner, G.P., Saatchi, S., Townsend, P., Miller, C., Frankenberg, C., Hibbard, K. & Cox, P. (2015) Observing terrestrial ecosystems and the carbon cycle from space. *Global Change Biology*, **21**, 1762–1776.
- Sitch, S., Huntingford, C., Gedney, N., Levy, P., Lomas, M., Piao, S. *et al.* (2008) Evaluation of the terrestrial carbon cycle, future plant geography and climate-carbon cycle feedbacks using five dynamic global vegetation models (dgvms). *Global Change Biology*, **14**, 2015–2039.
- van der Sleen, P., Groenendijk, P., Vlam, M., Anten, N.P.R., Boom, A., Bongers, F., Pons, T.L., Terburg, G. & Zuidema, P.A. (2015) No growth stimulation of tropical trees by 150 years of CO₂ fertilization but water-use efficiency increased. *Nature Geoscience*, **8**, 24–28.
- Stegen, J.C., Swenson, N.G., Enquist, B.J., White, E.P., Phillips, O.L., Jørgensen, P.M., Weiser, M.D., Monteagudo Mendoza, A. & Núñez Vargas, P. (2011) Variation in above-ground forest biomass across broad climatic gradients. *Global Ecology and Biogeography*, **20**, 744–754.
- Tadross, M., Randriamarolaza, L., Rabefitia, Z. & Ki Yip, Z. (2008) Climate change in Madagascar; recent past and future. Tech. rep, World Bank.
- Thuiller, W., Lavorel, S., Araujo, M.B., Sykes, M.T. & Prentice, I.C. (2005) Climate change threats to plant diversity in Europe. *Proceedings of the National Academy of Sciences*, **102**, 8245–8250.
- Tollefson, J. (2013) Experiment aims to steep rainforest in carbon dioxide. *Nature*, **496**, 405–406.
- Vieilledent, G., Grinand, C. & Vaudry, R. (2013b) Forecasting deforestation and carbon emissions in tropical developing countries facing demographic expansion: a case study in Madagascar. *Ecology and Evolution*, **3**, 1702–1716.
- Vieilledent, G., Vaudry, R., Andriamanohisoa, S.F.D., Rakotonarivo, O.S., Randrianasolo, H.Z., Razafindrabe, H.N., Rakotoarivony, C.B., Ebeling, J. & Rasamoelina, M. (2012) A universal approach to estimate biomass and carbon stock in tropical forests using generic allometric models. *Ecological Applications*, **22**, 572–583.
- Vieilledent, G., Cornu, C., Cuni Sanchez, A., Leong Pock-Tsy, J.M. & Danthu, P. (2013a) Vulnerability of baobab species to climate change and effectiveness of the protected area network in Madagascar: towards new conservation priorities. *Biological Conservation*, **166**, 11–22.
- Vieilledent, G., Gardi, O., Grinand, C., Burren, C., Andriamanjato, M., Camara, C., Gardner, C., Glass, L., Rasolohery, A., Ratsimba, H., Gond, V. & Rakotoarijaona, J.R. (2016) Data from: Bioclimatic envelope models predict a decrease in tropical forest carbon stocks with climate change in Madagascar. *Dryad Digital Repository*. <http://dx.doi.org/10.5061/dryad.9ph68>.
- Violle, C., Navas, M.L., Vile, D., Kazakou, E., Fortunel, C., Hummel, I. & Garnier, E. (2007) Let the concept of trait be functional! *Oikos*, **116**, 882–892.
- Wagner, F., Rossi, V., Aubry-Kientz, M., Bonal, D., Dalitz, H., Gliniars, R., Stahl, C., Trabucco, A. & Herault, B. (2014) Pan-tropical analysis of climate effects on seasonal tree growth. *PLoS ONE*, **9**, e92337.
- van der Werf, G.R., Morton, D.C., DeFries, R.S., Olivier, J.G.J., Kasibhatla, P.S., Jackson, R.B., Collatz, G.J. & Randerson, J.T. (2009) CO₂ emissions from forest loss. *Nature Geoscience*, **2**, 737–738.
- Zelazowski, P., Malhi, Y., Huntingford, C., Sitch, S. & Fisher, J.B. (2011) Changes in the potential distribution of humid tropical forests on a warmer planet. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, **369**, 137–160.
- Zhu, K., Woodall, C.W. & Clark, J.S. (2012) Failure to migrate: lack of tree range expansion in response to climate change. *Global Change Biology*, **18**, 1042–1052.

Received 19 August 2015; accepted 21 January 2016

Handling Editor: Emily Lines

Supporting Information


Additional Supporting Information may be found in the online version of this article:

Figure S1. Height-diameter relationship by forest type.

Figure S2. Comparison between ACD observations and model predictions.

Figure S3. Predicted climatic anomalies between years 2010 and 2080 in Madagascar forests.

Table S1. Forest carbon stock projections using seven IPCC CMIP5 global climate models.



National calibration of soil organic carbon concentration using diffuse infrared reflectance spectroscopy



Michaël Clairotte^{a,1}, Clovis Grinand^{b,c}, Ernest Kouakoua^b, Aurélie Thébault^{b,2}, Nicolas P.A. Saby^d, Martial Bernoux^b, Bernard G. Barthès^{b,*}

^a INRA, UMR Eco&Sols, 2 place Viala, 34060 Montpellier, France

^b IRD, UMR Eco&Sols, 2 place Viala, 34060 Montpellier, France

^c EctTerra, 127 rue d'Avron, 75020 Paris, France

^d INRA, Unité Infosol, BP 20619, 45166 Olivet, France

ARTICLE INFO

Article history:

Received 24 September 2015

Received in revised form 11 March 2016

Accepted 23 April 2016

Available online 14 May 2016

Keywords:

Soil organic carbon

Near infrared reflectance spectroscopy (NIRS)

Mid infrared reflectance spectroscopy (MIRS)

Global regression

Local regression

ABSTRACT

This study presents the potential of infrared diffuse reflectance spectroscopy (DRS) to predict soil organic carbon (SOC) content. A large national soil library was used, including about 3800 samples collected at two soil depths (0–30 and 30–50 cm) using a 16 × 16 km plot grid over the French metropolitan territory (552,000 km²). Reflectance spectra were collected in the laboratory using visible and near infrared (VNIR), near infrared (NIR) and mid infrared (MIR) spectrophotometers. The soil data library was broken down into calibration and validation sets through sample selection at random or based on spectral representativeness. The calibration intensity was investigated in order to assess the optimum number of calibration samples required to obtain accurate models. Predictions were achieved using global or local partial least square regression (PLSR) built using VNIR, NIR and MIR spectra separately or in combination. Local PLSR uses only calibration samples that are spectral neighbors of each validation sample, thus builds one model per validation sample. Model performance was evaluated on the validation set based on the standard error of prediction (SEP), the ratio of performance to deviation (RPD_v), and the ratio of performance to interquartile range (RPIQ_v).

Using all calibration samples, the global PLSR model provided the most precise predictions of SOC content with the MIR spectra, then with the NIR spectra, and less accurate predictions with the VNIR spectra (SEP = 2.6, 4.4 and 4.8 g kg⁻¹, RPD_v = 2.7, 2.3 and 1.5, and RPIQ_v = 3.3, 2.2 and 1.9, respectively). The combination of spectral libraries did not improve model performance noticeably. Local PLSR provided better models than global PLSR, allowing accurate predictions with only 30% of the calibration set, whatever the spectral library (RPD_v and RPIQ_v > 2.0). Optimum calibration intensity was estimated at about 60% for MIR spectra with both global and local PLSR, 30–40% for VNIR and NIR spectra with global PLSR, but 50% for VNIR spectra and 70% for NIR spectra with local PLSR. The most accurate models, which were obtained using the MIR spectra and local PLSR with calibration intensity higher than 50%, allowed very good SOC determination for the most frequent French soils (SEP < 2 g kg⁻¹). This highlights the potential of infrared DRS for national SOC monitoring, provided that calibration database is strengthened with samples from less frequent soil types.

© 2016 Elsevier B.V. All rights reserved.

1. Introduction

Organic carbon is a key component in soil, where it plays a central role in essential functions. Soil organic carbon (SOC) quantification enables to assess soil quality through its structural stability, water retention, as well as chemical and biological fertility (Vaughan and Malcolm, 1985; Reeves, 1997). In addition, as the greatest terrestrial

carbon pool, SOC is involved in global carbon cycling, thus in global warming (Batjes, 1996; Lal, 2004), with, for instance, an estimated amount of about 75 Mt SOC in the EU-27 (Schils et al., 2008). However, SOC declines across Europe to such an extent that it has become a dramatic threat (Lugato et al., 2014; De Brogniez et al., 2015).

With its ease to use, fast implementation and low cost, infrared diffuse reflectance spectroscopy (DRS) has become increasingly popular these last decades to estimate SOC (Gholizadeh et al., 2013; Soriano-Disla et al., 2014). In comparison with the traditional laboratory methods, infrared DRS does not require chemical reagents and tedious sample preparation, therefore, it can be quickly implemented in both laboratory and field conditions (Gras et al., 2014). The first studies demonstrating the capability of infrared DRS to determine SOC were based

* Corresponding author.

E-mail address: bernard.barthes@ird.fr (B.G. Barthès).

¹ Present address: European Commission Joint Research Centre Ispra, Institute for Energy and Transport, Sustainable Transport Unit, Ispra 21027, VA, Italy.

² Present address: ITK, Cap Alpha, avenue de l'Europe, 34830 Clapiers, France.

on visible and near infrared (VNIR), or only near infrared (NIR) spectral ranges (Ben-Dor and Banin, 1995; Shepherd and Walsh, 2002; Brown et al., 2005). Infrared DRS based on the mid infrared (MIR) spectral range has also demonstrated its ability to quantify SOC (Janik and Skjemstad, 1995; Grinand et al., 2012). Regarding information related to the chemical structure, the visible range is dominated by electronics transitions, the NIR range by the weak overtones and combinations of fundamental vibrations bands, and the MIR range by the fundamental vibrational bands for H—C, N—H and O—H bonds (Reeves, 2010).

Infrared DRS is generally based on calibrations, which require samples that have been characterized both conventionally (in the laboratory) and spectrally. Calibration models valid for large regions require large soil data libraries, and such libraries require demanding and expensive sampling and analysis campaigns (Nocita et al., 2015). Hence, calibration of soil properties has often been built from the scan of archived soil libraries (e.g., Genot et al., 2011; Viscarra Rossel and Webster, 2012; Shi et al., 2015). At the global scale, the ICRAF-ISRIC soil spectral library is composed of 4438 samples originating from Africa, Asia, Europe and America (van Reeuwijk, 1992). At the continental scale, there are several large soil spectral libraries, regarding Australia (21,500 spectra from samples collected during a lot of surveys; Viscarra Rossel and Webster, 2012), the United States (144,833 spectra from samples collected under the Rapid Carbon Assessment project; USDA, 2013), and Europe (20,000 spectra from samples collected under the Land Use/Cover Area Frame Statistical Survey – so-called LUCAS; Stevens et al., 2013). These large global- and continental-scale soil libraries were scanned in the VNIR range. There is also a French national-scale soil library, which has been scanned in both the VNIR (Gogé et al., 2012) and MIR (Grinand et al., 2012). Several studies have addressed the question of the spectral range most appropriate for predicting SOC concentration, considering VNIR, NIR and/or MIR (Viscarra Rossel et al., 2006; Brunet et al., 2008; Rabenarivo et al., 2013). However, the spectral libraries used in these comparisons included rather limited numbers of samples, and had local or regional application domains. Thus comparative studies based on large national soil libraries are scarce.

The scope of the present study was to assess the performances of SOC predictions made with a national soil spectral library, using VNIR, NIR and MIR spectra acquired with different spectrophotometers, individually or in combination. These instruments differed in terms of spectral range but also in terms of conception (e.g. more or less sophisticated dispersive elements); thus performances and comparisons did not refer strictly to spectral ranges, but rather, to spectral ranges and technologies. Moreover, different calibration strategies were tested:

- the proportion of calibration samples was varied for optimization purposes;
- calibration samples were either selected at random or according to their spectral representativeness;
- and calibration was either global (one unique model was built using all calibration samples) or local (one individual model was built for each validation sample, using calibration samples that were its spectral neighbors).

2. Materials and methods

2.1. The soil library

The studied soil samples belong to a large national soil library provided by the French national soil quality monitoring network (RMQS, Réseau de mesures de la qualité des sols). The RMQS aims at providing a national overview of soil quality, identifying gradients, monitoring the evolution of soil quality over time (with a frequency of a decade), and building a bank of soil samples (Arrouays et al., 2002). This soil library was built over a 10-year sampling campaign over the 552,000 km² of the French metropolitan territory. The sample design is based upon a square grid with spacing of 16 km (Fig. 1). At the center of each square, 25 individual core samples were taken at 0–30 and 30–50 cm depth




Fig. 1. The RMQS sampling grid.

using an unaligned sampling design within a 20 × 20 m area, and were then bulked to obtain composite samples (Arrouays et al., 2002). In total, the RMQS national soil library is composed by >2200 sites and 3800 samples covering numerous soil types: Cambisols, Calcosols, Luvisols, Leptosols, Andosols, Albeluvisols, etc. (FAO, 2014).

2.2. Reference analyses

Reference determinations were achieved in a single ISO/CEI 17025:2005 accredited laboratory (INRA soil analysis laboratory, Arras, France), according to the standard French procedure NF ISO 10694 (ISO, 1995a). In brief, the method consists in a dry combustion of the air dried, 2-mm sieved then finely ground (<0.25 mm) sample at circa 1200 °C in an oxygen-rich atmosphere. Thus, carbon is converted into carbon dioxide, and quantified using a thermal conductivity detector (TCD). This was done using a CHN elemental analyzer (Flash 2000, Thermo Scientific, Bremen, Germany). This analysis leads to the determination of total carbon content (g kg⁻¹), which was then corrected for inorganic carbon possibly present in the sample as carbonates. This was done according to the French procedure NF ISO 10693 (ISO, 1995b), which consists of measuring the volume of carbon dioxide produced after the addition of chlorhydric acid (Pansu and Gautheyrou, 2006). In order to not unduly influence the prediction models, samples with SOC content higher than the mean plus 10 times the standard deviation were considered outliers and removed from the studied sample population. This led to the removal from the soil library of three samples with SOC > 200 g kg⁻¹. The SOC content of the library then ranged from 0.6 to 177 g kg⁻¹, averaged 18.9 g kg⁻¹, and had a skewness value close to 3 (Fig. 2).

2.3. Spectral analysis

The soils were air dried, 2-mm sieved then finely ground (<0.2 mm), and oven dried overnight at 40 °C before spectral analysis. Three spectrophotometers were used in this study. Reflectance spectra in the VNIR region were acquired between 350 and 2500 nm (ca. 28,500 and 4000 cm⁻¹, respectively) at 1 nm interval using a portable system LabSpec 2500 (Analytical Spectral Devices, Boulder, CO, USA). This spectrophotometer is equipped with a halogen lamp source, a fixed

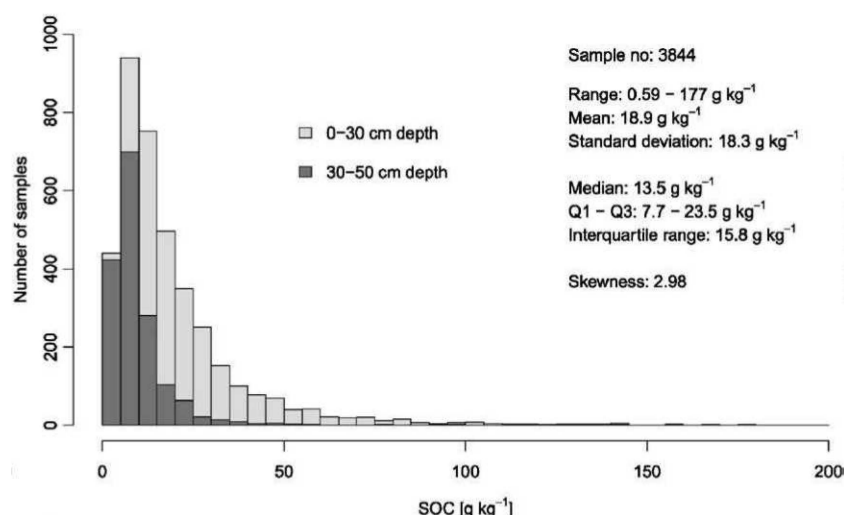


Fig. 2. Descriptive statistics and frequency histogram for SOC concentration in the studied soil library (after the removal of three samples with SOC > 200 g kg⁻¹). Q1 and Q3 stand for the first and third quartile, respectively.

diffraction grating, and a diode array detector. Soil samples were scanned manually with a contact probe (surface area scanned: 80 mm²). Each VNIR spectrum resulted from the averaging of 32 co-added scans, and absorbance zeroing was carried out every hour using a reference standard (Spectralon, i.e. polytetrafluoroethylene). VNIR spectra were used in the range from 400 to 2500 nm (25,000 and 4000 cm⁻¹, respectively), due to frequent noise at the spectrum lower end. Reflectance spectra in the NIR region were acquired between 1100 and 2500 nm (ca. 9091 and 4000 cm⁻¹, respectively) at 2 nm interval using a Foss NIRSystems 5000 (Laurel, MD, USA). This spectrophotometer is equipped with a halogen lamp source, a scanning grating as dispersive element and a PbS (lead sulfide) detector. Soil samples were placed in a ring cup with a quartz bottom, gently packed using a specific round cardboard, then scanned through the quartz window using a feeder for ring cups (soil surface area scanned: 42 mm²). Each NIR spectrum resulted from 32 co-added scans, and internal reference standard was scanned automatically before each sample. Finally, reflectance spectra in the MIR region were acquired between 4000 and 400 cm⁻¹ (2500 and 25,000 nm, respectively) at 3.86 cm⁻¹ interval using a Fourier transform Nicolet 6700 (Thermo Fischer Scientific, Madison, WI, USA). This spectrophotometer is equipped with a silicon carbide source, a Michelson interferometer as dispersive element, and a DTGS (deuterated triglycine sulfate) detector. Soil samples were placed in a 17-well plate, where their surface was flattened with the flat section of a glass cylinder, and they were then scanned using an auto-sampler (soil surface area scanned: ca. 10 mm²). Each MIR spectrum resulted from 32 co-added scans, and the body of the plate (beside wells) was used as reference standard and scanned once per plate (i.e. every 17 samples). MIR spectra were used in the range from 4000 to 450 cm⁻¹ (2500 and ca. 22,000 nm, respectively) because the spectrum end was often noisy. According to suppliers' recommendations, spectrometer warm-up was generally 30 min for the VNIR instrument, 60 min for the NIR instrument, while the MIR instrument was always turned on. To a wider extent, the spectrum acquisition procedure was kept as constant as possible for a given instrument, to limit the nonsystematic noise effects (Pimstein et al., 2011). Moreover, during the full scanning process, the spectrometers and associated accessories (e.g. the contact probe of the VNIR instrument) were not substituted and were properly maintained, in order to minimize the systematic noise effects (Pimstein et al., 2011; Ben-Dor et al., 2015). The reflectance spectra were converted into absorbance spectra [$\log_{10}(1/R)$] and gathered to form one global library (GL) per spectral range. In addition to the three GLs created using the different spectrophotometers, the spectra were combined to form extended spectral libraries. The NIR spectra acquired with the Foss instrument and the MIR spectra were combined

to create an extended library called hereinafter NIR + MIR. In the same way, another extended library composed by the so-called "visible" region of the VNIR (400 to 1100 nm), the NIR spectra acquired with the Foss instrument (1100 to 2500 nm) and the MIR region (2500 to 22,000 nm) was formed and called VIS + NIR + MIR.

Once the three outliers removed (cf. Section 2.2), sample number varied from 3781 to 3844 according to the GL considered, depending on the possible removal of replicated samples used for controlling reference analyses or exhaustion of some samples between scanning campaigns.

2.4. Selection and number of calibration samples

2.4.1. Selection of a tuning set

Based on spectral representativeness, each GL was divided into calibration, validation and tuning sets, hereinafter referred to as CAL.set, VAL.set, and TUN.set, respectively. Sample selection was based on the Kennard-Stone algorithm (Kennard and Stone, 1969), which was implemented in R 3.1.0 (R Development Core Team, 2011) together with the package "prospectr" (Stevens and Ramirez-Lopez, 2013). CAL.set included the 80% most representative spectra, VAL.set the 10% best represented ones (i.e. least representative), and TUN.set the 10% remaining ones (Fig. 3). This first operation aimed at single out the TUN.set required for the tuning stage of the local regression.

2.4.2. Optimal calibration intensity

The aim of this stage was to determine the minimum number of calibration samples required to ensure correct predictions. This was done by varying the number of calibration samples, following two selection strategies: random selection and selection based on spectral representativeness.

- For random selection, CAL.set and VAL.set were merged to form a secondary library (SL; cf. Fig. 3) and 380 samples were randomly selected (out of >3400) to create a new validation set, referred to as val.set. Then, the calibration intensity was investigated by selecting randomly from 10% to 90% of the samples within the remaining calibration set, referred to as cal.set; and finally, the highest calibration intensity was achieved using 100% of cal.set. Random selection was performed 10 times for each calibration intensity between 10% and 90%. In order to mitigate the influence of the initial val.set selection, the whole operation was carried out 10 times (i.e. with 10 different val.set).
- When based on spectral representativeness, sample selection involved the Kennard-Stone algorithm (Kennard and Stone, 1969). VAL.set was used for validation, while an increasing number of calibration samples was selected from CAL.set (from 10% to 100%).

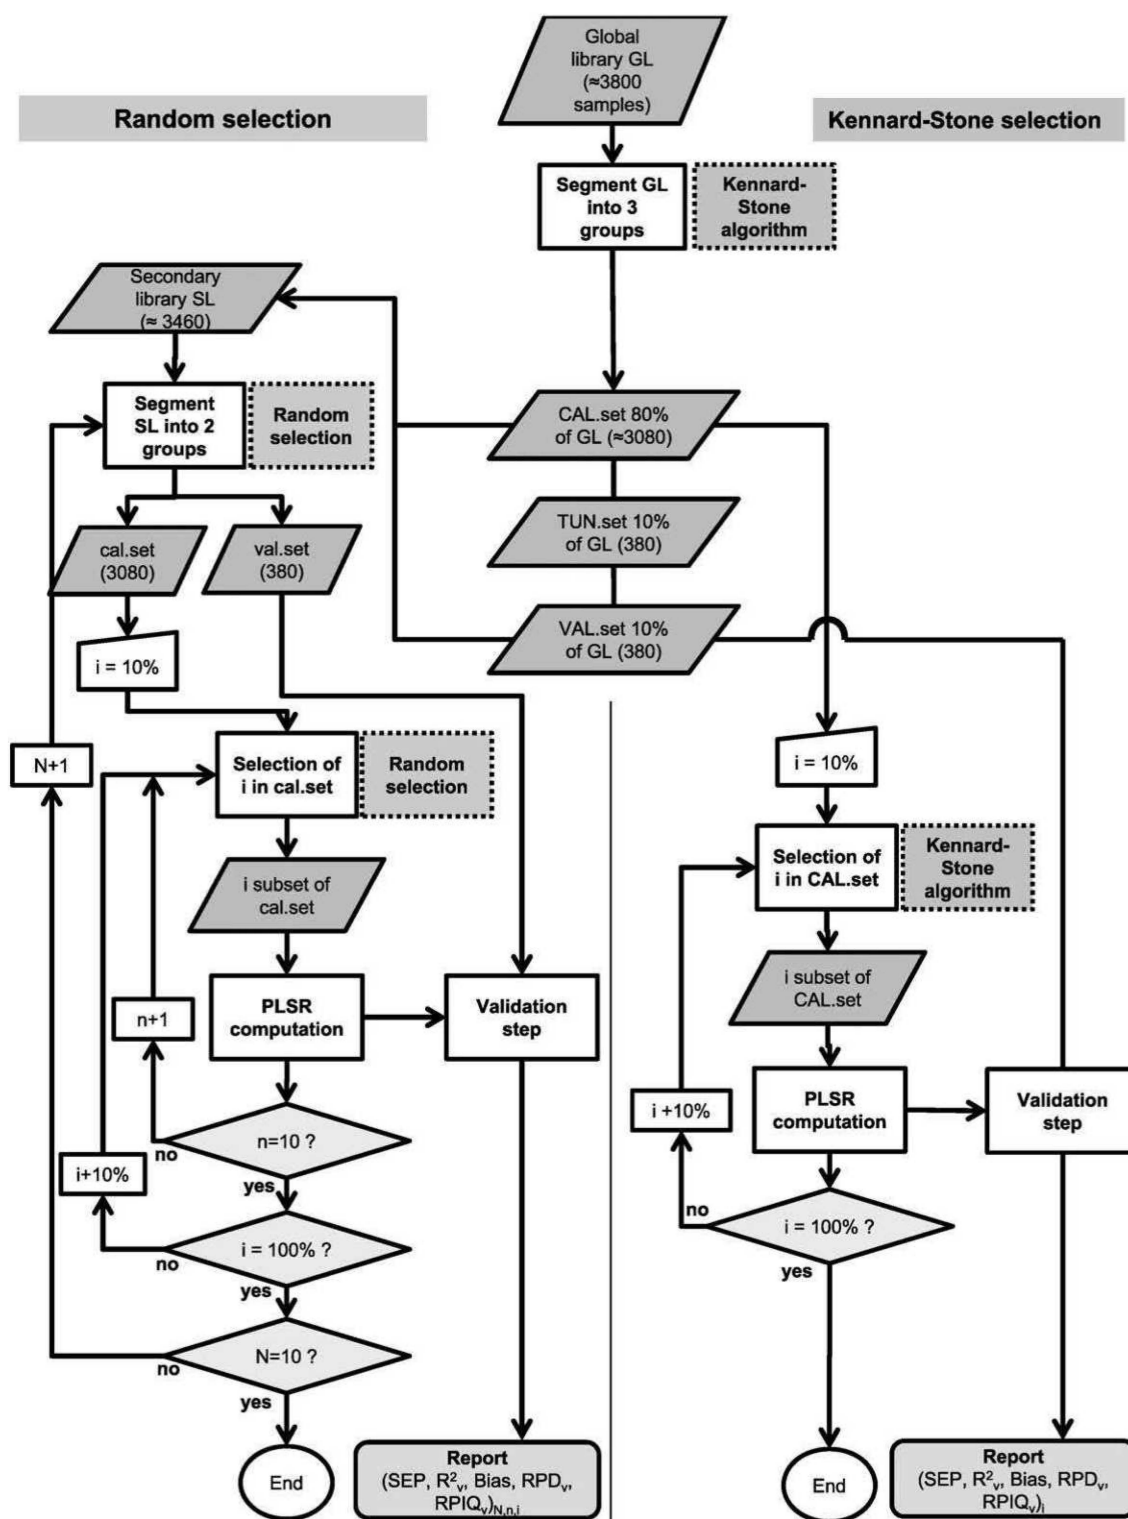


Fig. 3. Schematic diagram of the sample selection procedure and calibration intensity study. N stands for the number of random selection iterations for val.set (10 in total). n stands for the number of random selection iterations for cal.set (10 in total for each N). i (in %) stands for the calibration intensity (from 10 to 100% with 10% steps).

Calibration intensity with random selection of calibration samples was investigated in Grinand et al. (2012), but with the substantial difference that samples not used for calibration were transferred to the validation set, making its composition different at each calibration intensity level. Here, whatever the calibration set selection and size, the size of the validation set was constant (380 samples). However, the

VAL.set composition changed according to the spectral library considered, because composition depended on spectral representativeness, which depended on the spectral range.

The SOC content in CAL.set ranged from 0.6 g kg⁻¹ to 177 g kg⁻¹, with an average (ca. 20 g kg⁻¹) and a standard deviation (SD; ca. 19.5 g kg⁻¹) nearly constant whatever the spectral library considered (Table 1). There

Table 1

Descriptive statistics of the calibration, tuning and validation sets. N_s , M_s , SD_s , IQ_s and Sk_s stand respectively for the number of samples, mean, standard deviation, interquartile range and skewness coefficient of the set s (with $s = c$ for calibration, $s = t$ for tuning and $s = v$ for validation). M , SD , IQ and range are in $g\ kg^{-1}$.

Spectral library	Calibration set (CAL.set)						Tuning set (TUN.set)						Validation set (VAL.set)					
	N_c	M_c	SD_c	IQ_c	Range _c	Sk_c	N_t	M_t	SD_t	IQ_t	Range _t	Sk_t	N_v	M_v	SD_v	IQ_v	Range _v	Sk_v
VNIR	3048	20.2	19.3	17.5	0.6–177	2.7	380	13.9	9.4	11.8	0.6–73.2	1.7	380	12.1	7.4	9.3	1.1–45.3	1.3
NIR	3045	19.7	19.5	17.0	0.6–177	2.9	380	16.4	12.3	13.0	0.9–84.6	1.9	380	14.8	10.3	9.9	0.6–67.3	2.0
MIR	3084	20.5	19.6	17.8	0.6–177	2.8	380	14.1	9.8	8.7	1.7–62.8	2.0	380	11.3	6.9	8.5	1.5–55.8	1.9
NIR + MIR	3043	20.4	19.6	18.0	0.6–177	2.8	380	14.8	11.0	9.6	1.7–84.0	2.5	380	11.3	6.5	7.9	2.6–55.8	1.8
VIS + NIR + MIR	3021	20.2	19.2	17.9	0.6–177	2.7	380	14.8	11.3	10.4	0.9–82.0	2.4	380	11.0	5.8	7.5	2.6–35.6	1.1

were small differences in mean and SD between the different CAL.set because the set size was not exactly the same and because the most representative samples were not necessarily the same. In contrast, the mean and SD of TUN.set and, to a greater extent, VAL.set, varied noticeably according to the spectral library.

2.5. Regression procedures

Partial least squares regression (PLSR) was used to infer SOC content from the spectra. This was done using either global or local PLSR. Global PLSR, which is the common PLSR procedure, uses all calibration samples to be used (depending on the calibration intensity) for building a unique model that will be applied on all validation samples (Shenk and Westerhaus, 1991). The number of latent variables that minimized the root mean square error of cross-validation (RMSECV) was retained for the prediction model. The cross-validation was carried out by dividing the calibration set into six groups composed of a nearly equal number of randomly selected samples. Global PLSR was implemented in R together with the package “pls” (Mevik and Wehrens, 2007).

In contrast, local PLSR makes prediction for each sample individually, only using calibration samples that are its spectral neighbors (Shenk et al., 1997). These neighbors were selected according to two metrics: the correlation coefficient between spectra and the Mahalanobis distance H (i.e. in the principal component space; Mark and Tunnell, 1985). The distance H was calculated on the number of principal components that minimized the root mean square (RMS) deviation of SOC difference between every calibration sample and its closest spectral neighbor, so that spectral neighbors also tended to be “SOC neighbors”, according to Ramirez-Lopez et al. (2013a). Moreover, the number of latent variables was not determined through cross-validation, which would require long calculation. Instead, each prediction was calculated as the weighted average of the predicted values generated with 7 to 25 latent variables (different maximums were tested), each weight being calculated as the inverse of the product of the RMS of X-residuals (i.e. the difference between the actual spectrum and the spectrum approximated using the considered number of latent variables) and RMS of the regression coefficients (Shenk et al., 1997; Zhang et al., 2004).

In order to not over-fit local PLSR, the optimum number of neighbors and optimum distance metric were determined on TUN.set (Fig. 3). Then, these optimum parameters were used to predict SOC content on VAL.set. As local PLSR requires a lot of computational time to build one model per sample to predict, it was only carried out when the calibration samples were selected based on their spectral representativeness. Local PLSR was implemented in R together with the spectrum-based learner algorithms from the package “resemble” (Ramirez-Lopez et al., 2013b).

For both global and local PLSR and each spectral library, different and common spectrum pre-processing methods were tested, in order to identify the most appropriate: mean centering, variance scaling, moving average, standard normal variate (SNV, i.e. mean centering and variance scaling), Savitzky-Golay smoothing and derivative, and continuum removal. The pre-processing yielding the lowest RMSECV was selected.

Pre-processing methods were implemented in R together with the package “prospectr” (Stevens and Ramirez-Lopez, 2013).

The accuracy of the prediction models was estimated on the validation set (either val.set after random selection of calibration samples or VAL.set after Kennard-Stone selection) by computing the standard error of prediction (SEP), coefficient of determination (R^2_v), ratio of performance to deviation ($RPD_v = SD_v / SEP$, where SD_v is the SD of the validation set) and ratio of performance to interquartile range ($RPIQ_v = IQ_v / SEP$, where IQ_v is the interquartile range of the validation set), more appropriate than RPD_v for non-normal distributions (Bellon-Maurel et al., 2010).

Neither spectral outlier detection nor calibration outlier detection were achieved. The only samples removed from spectral analyses were the three with SOC content $> 200\ g\ kg^{-1}$ (cf. Section 2.2).

3. Results and discussion

3.1. Spectrum pre-processing

The best pre-processing method was identified on each GL through cross-validation. Moving average on 10 bands followed by Savitzky-Golay first derivative gave the best cross-validation for the MIR and VIS + NIR + MIR libraries; but moving average on 10 bands was enough for VNIR and NIR libraries (data not shown). This contrasted with the results of Vasques et al. (2008), where Savitzky-Golay first derivative was the best pre-processing method for VNIR spectra, in agreement with the review of Gholizadeh et al. (2013) on infrared DRS for SOC content prediction. No pre-processing functions improved the results for the NIR + MIR library.

3.2. Global PLSR

The validation results are presented in Fig. 4, for the different selection strategies, spectral libraries and calibration intensities. More detailed results for 30%, 50% and 100% calibration intensity are shown in Table 2.

3.2.1. Overall validation results after random selection of calibration samples

In that case SEP decreased smoothly with increasing calibration intensity, except at low calibration intensities, especially for NIR, MIR and NIR + MIR libraries (Fig. 4A). Obviously, the more samples allocated in the calibration set, the more information available to build accurate models; however the benefit of 10% additional calibration samples was very limited at high calibration intensities (from 60 to 70%). In the same way, RPD_v and $RPIQ_v$ increased progressively with calibration intensity, with limited increase at high intensities (Fig. 4C and E).

The libraries including the MIR spectra provided greater accuracy than the other spectral libraries: the best models were achieved with the MIR, NIR + MIR and VIS + NIR + MIR libraries ($SEP = 6\ g\ kg^{-1}$, $RPD_v \geq 3$ and $RPIQ_v = 2.8$ at 100% calibration intensity), while NIR and to a greater extent VNIR libraries yielded noticeably poorer results ($8\text{--}9\ g\ kg^{-1}$, $2.1\text{--}2.3$ and $1.9\text{--}2.1$, respectively). These results are

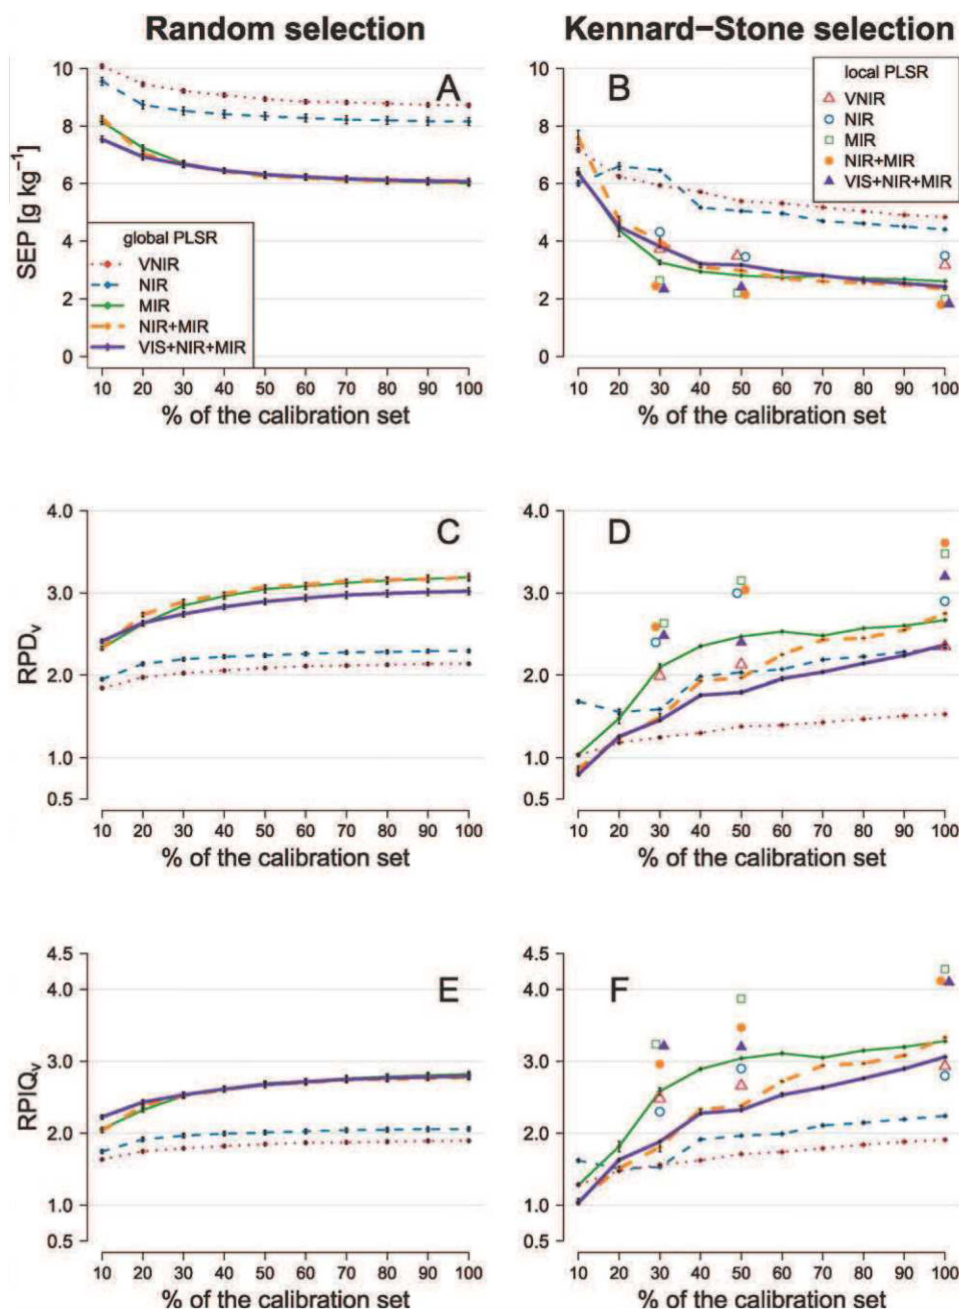


Fig. 4. Performance of the SOC content predictions on the validation sets after calibration sample selection at random (left) or according to the Kennard-Stone procedure (right), using global or local PLSR models built at 10 calibration intensities (10% to 100%; local PLSR only with Kennard-Stone selection and for 30%, 50% and 100% intensities).

consistent with RPD values reported by a regional-scale study (3585 km²) carried out in Florida using VNIR spectra (Vasques et al., 2008).

Hierarchies in SEP and RPIQ_v were similar across spectral libraries but RPD_v behaved sometimes differently (Table 2). Indeed, random segmentation of the secondary library (cf. Section 2.4 and Fig. 3) caused small differences in SD_v and thus RPD_v, while IQ_v and thus RPIQ_v were poorly affected.

3.2.2. Overall validation results after selection of spectrally representative calibration samples

Model accuracy increased more markedly with calibration intensity after Kennard-Stone selection than after random selection of calibration samples: from 10% to 100% calibration intensity, averaged over the five spectral libraries, SEP decreased twice more after Kennard-Stone selection than after random selection (3.4- vs. 1.7-g kg⁻¹ decrease), RPD_v

increased twice more (1.3 vs. 0.6 increase) and RPIQ_v three times more (1.5 vs. 0.5 increase; Fig. 4B, D and F). Moreover, adding calibration samples was useful even at high calibration intensities. This indicated that the calibration set contained more information useful for characterizing the validation samples when calibration samples were selected according to their spectral representativeness, which makes sense. Furthermore, increase in prediction accuracy with calibration intensity was not completely regular, and some disruptions occurred, for instance with the NIR spectra at 20–30% intensity. Indeed, increasing calibration intensity was carried out by increasing the number of calibration samples spectrally representative of CAL.set, which did not necessarily correspond to a better representation of VAL.set (cf. Fig. 3).

The most accurate models were obtained with the MIR and NIR + MIR spectra (SEP = 2.3–2.6 g kg⁻¹, RPD_v = 2.7–2.8 and RPIQ_v = 3.3 at 100% calibration intensity), the least accurate with the VNIR spectra (4.8 g kg⁻¹, 1.5 and 1.9, respectively), while intermediate

Table 2

Predictions of SOC content on the validation sets using global PLSR models built with 30%, 50% or 100% of the calibration samples selected at random or according to the Kennard-Stone procedure.

Spectral library	N _c	Random selection (N _v = 380)							Kennard-Stone selection (N _v = 380)								
		SD _v	IQ _v	SEP	Bias	R ² _v	RPD _v	RPIQ _v	SD _v	IQ _v	SEP	Bias	R ² _v	RPD _v	RPIQ _v		
		g kg ^{−1}							g kg ^{−1}								
Calibration intensity: 30%																	
VNIR	900	18.6	16.4	9.2	−0.2	0.76	2.0	1.8	7.4	9.3	5.9	0.3	0.67	1.3	1.6		
NIR	900	18.6	16.4	8.5	−0.2	0.80	2.2	2.0	10.3	9.9	6.5	0.2	0.79	1.6	1.5		
MIR	900	18.9	16.6	6.7	0.3	0.87	2.8	2.5	6.9	8.5	3.3	−0.5	0.87	2.1	2.6		
NIR + MIR	900	19.5	16.7	6.7	0.0	0.88	2.9	2.5	6.5	7.9	4.0	1.9	0.84	1.5	1.8		
VIS + NIR + MIR	900	18.0	16.5	6.7	−0.2	0.86	2.7	2.5	5.8	7.5	3.8	1.1	0.82	1.5	1.9		
Calibration intensity: 50%																	
VNIR	1500	18.6	16.4	8.9	−0.2	0.77	2.1	1.8	7.4	9.3	5.4	0.4	0.69	1.4	1.7		
NIR	1500	18.6	16.4	8.3	−0.2	0.81	2.2	2.0	10.3	9.9	5.0	0.1	0.85	2.0	2.0		
MIR	1500	18.9	16.6	6.3	0.2	0.89	3.0	2.7	6.9	8.5	2.8	0.2	0.88	2.5	3.0		
NIR + MIR	1500	19.5	16.7	6.3	0.1	0.89	3.1	2.7	6.5	7.9	3.0	1.5	0.87	2.0	2.4		
VIS + NIR + MIR	1500	18.0	16.5	6.3	−0.2	0.88	2.9	2.7	5.8	7.5	3.2	0.6	0.84	1.8	2.3		
Calibration intensity: 100%																	
VNIR	3048	18.6	16.4	8.7	−0.2	0.78	2.1	1.9	7.4	9.3	4.8	0.3	0.73	1.5	1.9		
NIR	3045	18.6	16.4	8.2	−0.2	0.81	2.3	2.1	10.3	9.9	4.4	0.3	0.87	2.3	2.2		
MIR	3084	18.9	16.6	6.0	0.2	0.90	3.2	2.8	6.9	8.5	2.6	0.1	0.88	2.7	3.3		
NIR + MIR	3043	19.5	16.7	6.0	0.0	0.90	3.2	2.8	6.5	7.9	2.3	0.4	0.89	2.8	3.3		
VIS + NIR + MIR	3021	18.0	16.5	6.1	−0.2	0.89	3.0	2.8	5.8	7.5	2.4	0.4	0.87	2.4	3.1		

N_c , N_v : calibration and validation sample number, respectively.

SD_v , IQ_v : standard deviation and interquartile range of the validation set, respectively.

SEP: standard error of prediction.

R^2_v : determination coefficient for validation.

RPD_v: ratio of SD_v to SEP.

RPIQ_v: ratio of the interquartile range to SEP.

results were achieved with the NIR and VIS + NIR + MIR spectra (RPD_v = 2.3–2.4 but SEP = 4.4 and 2.4 $g\ kg^{-1}$, and RPIQ_v = 2.2 and 3.1, respectively, due to noticeable differences in SD_v ; Table 2). For the VNIR library, RPD_v increased relatively little with calibration intensity and always remained below the often cited threshold of 2, beyond which soil property prediction models have been considered suitable (Chang et al., 2001). Comparisons on the validation set between SOC content measured (reference) and predicted using the different spectral libraries and global PLSR built with 100% of the calibration samples selected by the Kennard-Stone procedure are presented in Fig. 5A.

As seen for random selection but to a greater extent here, the way spectral ranges ranked was not the same according to SEP or RPD_v: for calibration intensity $\geq 30\%$, SEP was moderately higher with VNIR than with NIR spectra, and much lower with the libraries that included the MIR spectra; while RPD_v discriminated low values for the VNIR library, much higher values for NIR and VIS + NIR + MIR libraries, and even higher values for MIR and NIR + MIR libraries. This discrepancy was due to differences in SD_v , (the SD_v of VAL.set ranged from 5.8 $g\ kg^{-1}$ to 10.3 $g\ kg^{-1}$ depending on the library). There was less variation in IQ_v (from 7.5 to 9.9 $g\ kg^{-1}$), and as a consequence, RPIQ_v and SEP




Fig. 5. Comparisons between SOC contents measured (reference) and predicted on the validation set using VNIR, NIR, MIR, NIR + MR or VIS + NR + MIR spectra and global (A) or local (B) PLSR built with 100% of the calibration samples, selected by the Kennard-Stone procedure.

reflected more comparable trends, in particular, noticeably better results with VIS + NIR + MIR than with NIR spectra. These effects of spectral range and instrument are discussed more specifically in Section 3.2.5.

3.2.3. Respective variations of SEP, RPD_v and RPIQ_v after Kennard-Stone vs. random selection of calibration samples

Surprisingly, though SEP was much lower after Kennard-Stone than after random selection of the calibration samples (–50% in average at 100% calibration intensity), in general RPD_v was lower too because SD_v was even much lower. In contrast, RPIQ_v was often higher after Kennard-Stone than after random selection, especially at high calibration intensities, because SEP decreased more than IQ_v (reminder: $RPIQ_v = IQ_v / SEP$ while $RPD_v = SD_v / SEP$). Indeed, after Kennard-Stone selection, samples with extreme SOC values were more likely to be in the calibration set, and logically this affected SD_v more markedly than IQ_v. This underlines that RPIQ_v is a more appropriate performance parameter than RPD when considering very skewed variable distributions (Bellon-Maurel et al., 2010).

Moreover, after random selection of calibration samples, RPD_v was higher than RPIQ_v, but except for the NIR library, the opposite was seen after Kennard-Stone selection. This also related to SD_v and IQ_v variations according to the selection procedure. As a result of random selection of calibration samples, the total, calibration and validation sets indeed had similar SD, and similar IQ. In contrast, Kennard-Stone selection of calibration samples resulted in higher SD and IQ in the calibration set than in the total set, and to a greater extent, than in the validation set. Thus SD_v and IQ_v were smaller after Kennard-Stone than after random selection of calibration samples, and the decrease was higher for SD_v than for IQ_v, as mentioned above.

3.2.4. Calibration intensity

After random selection of calibration samples, the improvement of the model performance with calibration intensity was greater when the MIR spectra were involved: RPD_v (or RPIQ_v) increased by 30% over the full intensity range, compared to 15% for NIR or VNIR spectra (Table 2, Fig. 4C and E). Optimum calibration intensity (i.e. minimum number of calibration samples required to obtain a sufficiently accurate model) could be set at 50–60% of the calibration set when the MIR spectra were involved, but at only 30–40% for the NIR and VNIR libraries. The models with VNIR or NIR spectra reached their optimum more rapidly, probably because these spectra contained less useful information for predicting SOC, and less calibration samples were needed for extracting this information.

After Kennard-Stone selection of calibration samples, optimum calibration intensity was more difficult to draw up. This optimum was generally reached with larger calibration sets than after random selection. The best cost/benefit tradeoff could be set at 50% calibration intensity for the VNIR library, 60% for the MIR library, 70% for the NIR and NIR + MIR libraries, and 100% for the VIS + NIR + MIR library (Table 2, Fig. 4D and F). It is worth noting that such optimum depends on the specific context of each given study, especially the financial means available (more funding allows higher calibration intensity) and the objective of the study (e.g. detecting small SOC changes requires high prediction accuracy thus high calibration intensity).

Considering a MIR database that included only the topsoil samples from the present study (i.e. 2086 samples ground at 0.2 mm), Grinand et al. (2012) performed global PLSR with random selection of calibration samples (10 replicates) and achieved optimal calibration intensity at 40% of the total population ($RPD_v = 3.2$). However, their validation set included all samples not used for calibration, thus its size decreased when calibration intensity increased, which did not allow easy comparison with the present study (where 100% calibration intensity actually represented 80% of the total set). Shepherd and Walsh (2002) used multivariate adaptive regression splines (MARS, a data mining approach) for predicting SOC content in a very diverse VNIR dataset of 2-mm

sieved topsoil samples from eastern and southern Africa (1100 samples from seven countries representing 10 soil orders). Considering a constant validation set, they achieved optimum calibration intensity with 35% randomly selected samples (out of the total set). Brown et al. (2005) studied a more homogeneous set made of profile samples (ca. 300 samples, 2 mm sieved) from six sites in north central Montana (200-km wide area; USA). Using VNIR and global PLSR for predicting SOC content, they reached an optimum when using 50% randomly selected samples for calibration (out of the total set), but 33% only when randomly selecting samples grouped by profile. Actually, optimal calibration intensity depends on the soil library, on its diversity especially, which renders comparison between studies difficult.

3.2.5. Effects of spectral range and instrument on SOC prediction

On the whole, prediction was more accurate when the MIR spectra were involved. This is consistent with the literature review published by Bellon-Maurel and McBratney (2011), which stated that SOC content predictions made with spectra acquired on dried and ground sample were more accurate using MIR. This has been attributed to the fact that the MIR region displays much more details and is dominated by intensive vibration fundamentals, while the NIR region is dominated by weaker and broader signals from vibration overtones and combination bands (Janik et al., 1998; McCarty et al., 2002). However, most comparisons between SOC content predictions made with MIR vs. NIR spectra have been obtained on soils from temperate regions. Different results might be observed with soils from tropical regions, as indicated by works that have reported more accurate SOC predictions with NIR than MIR spectra in Brazil (Madari et al., 2006) or Madagascar (Rabenarivo et al., 2013). In addition, the results of the present study confirmed that VIS does not provide much additional information (Brunet et al., 2008), at least with the spectrometers used in this study. It is worth noting that most comparisons between SOC predictions made using different spectral regions were based on local or regional datasets, composed of a few soil types, which limited their significance when compared with the results of the present study.

Regardless of the selection strategy and the calibration intensity, prediction models were not improved notably by the combination of libraries (VIS + NIR + MIR and NIR + MIR), when compared with the MIR library alone. This is in accordance with Viscarra Rossel et al. (2006), who observed similarly accurate SOC predictions when using VIS + NIR + MIR and MIR spectra on a local-scale soil library (17.5 ha, 118 samples). MIR spectra contain the fundamental vibrational bands of the main chemical bonds found in organic matter, and information contained in the VIS and NIR ranges may be redundant, at least for soils from temperate regions.

The instrument technology might also contribute to the differences observed in prediction accuracy. Firstly, the different dispersive elements used in the VNIR and NIR spectrometers (fixed grating and scanning grating elements, respectively) could explain why the narrower NIR spectra provided better model accuracy than the broader VNIR spectra. The VNIR spectrometer used in the study is a portable instrument, dedicated to both laboratory and field measurements. Consequently, it is equipped with a robust fixed grating element (without mobile parts and sophisticated optical system), which allows fast measurements, but as a tradeoff, is slightly less accurate than a scanning grating element. Secondly, there were differences in the scanning procedure. The acquisition of VNIR spectra was done manually using a contact probe, and zeroing was done by the operator, every hour. In contrast, NIR and MIR spectrum acquisitions were automated, with internal zeroing before every scan. Suggestions have been proposed in order to improve spectrum acquisition with the VNIR spectrometer considered, mainly through the control of indirect interferences with external factors (i.e. duration of the spectrometer warm-up, type and number of reference acquisitions prior sample acquisition, etc.) and online spectrum correction using an internal soil standard (Pimstein et al., 2011; Ben-Dor et al., 2015). Furthermore, with the spectrometer used,

MIR spectra are acquired on a very small surface area (10 mm² vs. 42 and 80 mm² for the NIR and VNIR spectrometers, respectively), which makes it necessary to grind the samples finely (<0.2 mm) to limit its heterogeneity. Grinding is not particularly required for the two other instruments though it often results in better SOC content predictions, as stated for NIR by Barthes et al. (2006) and Brunet et al. (2007).

3.2.6. Interpretation of regression coefficients

Regression coefficients of global PLSR models obtained using all calibrations samples selected by the Kennard-Stone procedure with NIR, MIR and NIR + MIR spectra were investigated, after SNV transformation of NIR and MIR spectra (Fig. 6). The overall pattern expressed by the MIR regression coefficients was for the most part similar when the regression was performed using MIR alone and the combination NIR + MIR ($R^2 = 0.71$); nevertheless some regions had heavy contributions in one case only (e.g. 2780 nm positively for MIR alone and 2700 nm negatively for NIR + MIR), or their respective contribution might change (e.g. peaks at 3300 and 6000 nm). On the whole, similar heavily contributing bands were also observed in the NIR region when considering NIR alone and NIR + MIR ($R^2 = 0.41$), but their respective weights might vary (e.g. highest positive weight at 2350 nm for NIR alone and at 2100 nm for NIR + MIR), and some were even flattened dramatically (e.g. the region 1500–1800 nm from NIR alone to NIR + MIR). It is worth noting that for the combination NIR + MIR, the heaviest contributions were in the MIR, which might confirm that the MIR spectra contain more useful information for SOC content prediction than the NIR spectra, at least for the soils considered.

The absorption peak A around 1910 nm (5236 cm⁻¹; cf. Fig. 6) has been assigned to the bending and stretching vibrations of the O–H bounds in free water (Viscarra Rossel et al., 2006). Viscarra Rossel and Webster (2012) found that absorbance at this wavelength was crucial in the model trees they used to predict SOC content from VNIR spectra. The wide absorption peak B around 2050–2150 nm (4878–4651 cm⁻¹) has been attributed to different organic molecules such as amides or proteins (2050–2060 nm especially), polysaccharides (2100 nm) and lipids (2140 nm; Workman and Weyer, 2008). The absorption peak C around 3460 nm (2890 cm⁻¹) has been assigned to aliphatic C–H bounds of methyl and methylene groups (Vohland et al., 2014), which

is not particularly informative, and the peak D around 5747 nm (1740 cm⁻¹) to C=O bound from carboxyl acids, aldehydes and ketones (Janik et al., 1998). Both strong negative peaks E around 4000 nm (2500 cm⁻¹) and F around 5525 nm (1810 cm⁻¹) have been assigned to carbonates (Miller and Wilkins, 1952; Grinand et al., 2012).

3.3. Local PLSR

In order to limit computation time, local PLSR was carried out only for a few calibration intensities identified as significant using global PLSR: 30%, 50% and 100% (Table 3; Fig. 4B, D and F). Prediction of SOC content was greatly enhanced with local PLSR; however the performance ranking of spectral libraries remained globally similar in comparison with the global PLSR: the best models were obtained using the MIR spectra (or combinations including the MIR spectra) and the least accurate using the VNIR spectra only. When the MIR spectra and 100% of the calibration set were used, the best models had $SEP \leq 2 \text{ g kg}^{-1}$, $R^2_v > 0.9$, $RPD_v > 3$ and $RPIQ_v > 4$, which has never been reported at that scale to date. This of course concerned the best represented samples of the total population; nevertheless it may be hypothesized that such very good results could be extended to a larger proportion of the French territory by enriching the calibration database with soil types poorly represented currently. It is worth noting that local PLSR produced good models (RPD_v and $RPIQ_v \geq 2$) with all spectral libraries even at only 30% calibration intensity. Moreover, the difference in performance between prediction models using VNIR and NIR spectra was less marked using local than global PLSR. Globally, this improvement through local PLSR tended to decrease when calibration intensity increased (e.g. at 30%, 50% and 100% calibration intensity, $RPIQ_v$ increased by 53%, 44% and 33% in average, respectively) and was higher for the VNIR library (+56% $RPIQ_v$ in average considering the three intensities vs. +40% in average for the four other libraries). Noticeable performance increase from global to local PLSR was also observed by Shi et al. (2015) on a large Chinese dataset studied in the VNIR range (2732 topsoil samples, with 90% representative in terms of SOC content used for calibration): SEP decreased from 8.4 to 6.6 g kg⁻¹, RPD_v increased from 1.4 to 1.8, and $RPIQ_v$ from 1.5 to 2.3; performance was even better when local PLSR was carried out with calibration samples that were simultaneously spectral and geographical neighbors of validation samples (SEP , RPD_v and $RPIQ_v$ reached 6.0 g kg⁻¹, 2.0 and 2.6, respectively).

In the present study, optimal local PLSR parameters were estimated on the TUN.set. The optimal distance metric was systematically the Mahalanobis distance H for VNIR and NIR libraries, in accordance with Ramirez-Lopez et al. (2013a). However, the optimal distance metric was the correlation coefficient for the MIR library, while no systematic optimal distance metric could be found for combinations of spectral libraries. For the calibration intensities studied, the optimal number of neighbors ranged from 210 to 300 samples for VNIR, from 150 to 360 for NIR, from 180 to 540 for MIR, from 180 to 690 for NIR + MIR, and from 330 to 510 for VIS + NIR + MIR. It tended to increase with calibration intensity, especially when the MIR spectra were involved. Comparisons on the validation set between SOC content measured (reference) and predicted using VNIR, NIR, MIR, NIR + MIR or VIS + NIR + MIR spectra and global or local PLSR built with 100% of the calibration samples selected by the Kennard-Stone procedure are presented in Fig. 5.

Using the best parameters defined above, it was possible to perform local PLSR on the whole spectral library to predict SOC on new samples originating from France. This was tested with the MIR library, for each sample of the current database successively, using all other samples of the database as potential calibration samples (depending on their distance to the sample to be predicted). In that manner, the Fig. 7 presents maps of SOC content in France at 0–30 and 30–50 cm depth, using reference data vs. MIR predictions. For a given depth layer, both maps displayed a strong similarity, with a $RPIQ_v$ of 3.4 ($RPD_v = 3.9$) obtained for the full GL.




Fig. 6. Regression coefficients of global PLSR using NIR, MIR or NIR + MIR spectra of 100% of the calibration set selected by the Kennard-Stone procedure (with SNV pre-processing).

Table 3
Predictions of SOC content on the tuning and validation sets using local PLSR models built at three calibration intensities, with calibration samples selected according to the Kennard-Stone procedure (using the pre-processing that minimized the standard error of tuning, SET).

Spectral library	N _c	Tuning set (N _t = 380)							Validation set (N _v = 380)						
		N _{neigh}	SD _t	IQ _t	SET	R ² _t	RPD _t	RPIQ _t	SD _v	IQ _v	SEP	Bias	R ² _v	RPD _v	RPIQ _v
		g kg ^{−1}							g kg ^{−1}						
Calibration intensity: 30%															
VNIR	900	210	9.4	11.8	4.6	0.81	2.1	2.6	7.4	9.3	3.7	0.1	0.77	2.0	2.5
NIR	900	150	12.3	13.0	4.9	0.85	2.5	2.7	10.3	9.9	4.3	0.0	0.85	2.4	2.3
MIR	900	180	9.8	8.7	2.7	0.93	3.6	3.1	6.9	8.5	2.6	−0.2	0.88	2.6	3.2
NIR + MIR	900	180	11.0	9.6	3.1	0.92	3.6	3.1	6.5	7.9	2.4	0.6	0.89	2.6	3.0
VIS + NIR + MIR	900	330	11.3	10.4	2.8	0.94	3.9	3.6	5.8	7.5	2.3	0.2	0.89	2.5	3.2
Calibration intensity: 50%															
VNIR	1500	300	9.4	11.8	3.8	0.84	2.5	3.1	7.4	9.3	3.5	0.2	0.79	2.1	2.7
NIR	1500	360	12.3	13.0	4.2	0.89	3.0	3.1	10.3	9.9	3.5	−0.1	0.89	3.0	2.9
MIR	1500	240	9.8	8.7	2.2	0.95	4.4	3.8	6.9	8.5	2.2	0.0	0.90	3.2	3.9
NIR + MIR	1500	180	11.0	9.6	2.4	0.96	4.3	3.8	6.5	7.9	2.1	−0.2	0.92	3.0	3.5
VIS + NIR + MIR	1500	480	11.3	10.4	2.9	0.94	3.8	3.5	5.8	7.5	2.4	0.3	0.87	2.4	3.2
Calibration intensity: 100%															
VNIR	3048	270	9.4	11.8	3.5	0.86	2.7	3.4	7.4	9.3	3.2	0.0	0.82	2.4	2.9
NIR	3045	180	12.3	13.0	3.6	0.92	3.4	3.6	10.3	9.9	3.5	−0.3	0.89	2.9	2.8
MIR	3084	540	9.8	8.7	2.0	0.96	4.9	4.3	6.9	8.5	2.0	0.0	0.92	3.5	4.3
NIR + MIR	3043	690	11.0	9.6	2.1	0.96	5.2	4.5	6.5	7.9	1.8	0.3	0.94	3.6	4.1
VIS + NIR + MIR	3021	510	11.3	10.4	2.0	0.97	5.7	5.2	5.8	7.5	1.8	0.3	0.91	3.2	4.1

N_c , N_t , N_v : calibration, tuning and validation sample number, respectively.

N_{neigh} : number of neighbors minimizing SET.

SD_t , SD_v , IQ_t and IQ_v : standard error and interquartile range of the tuning and validation sets, respectively.

SET, SEP: standard error of tuning and of prediction, respectively.

R^2_t , R^2_v , RPD_t , RPD_v , $RPIQ_t$ and $RPIQ_v$: determination coefficient, ratio of SD to standard error, and ratio of interquartile range to standard error, for tuning and validation, respectively.

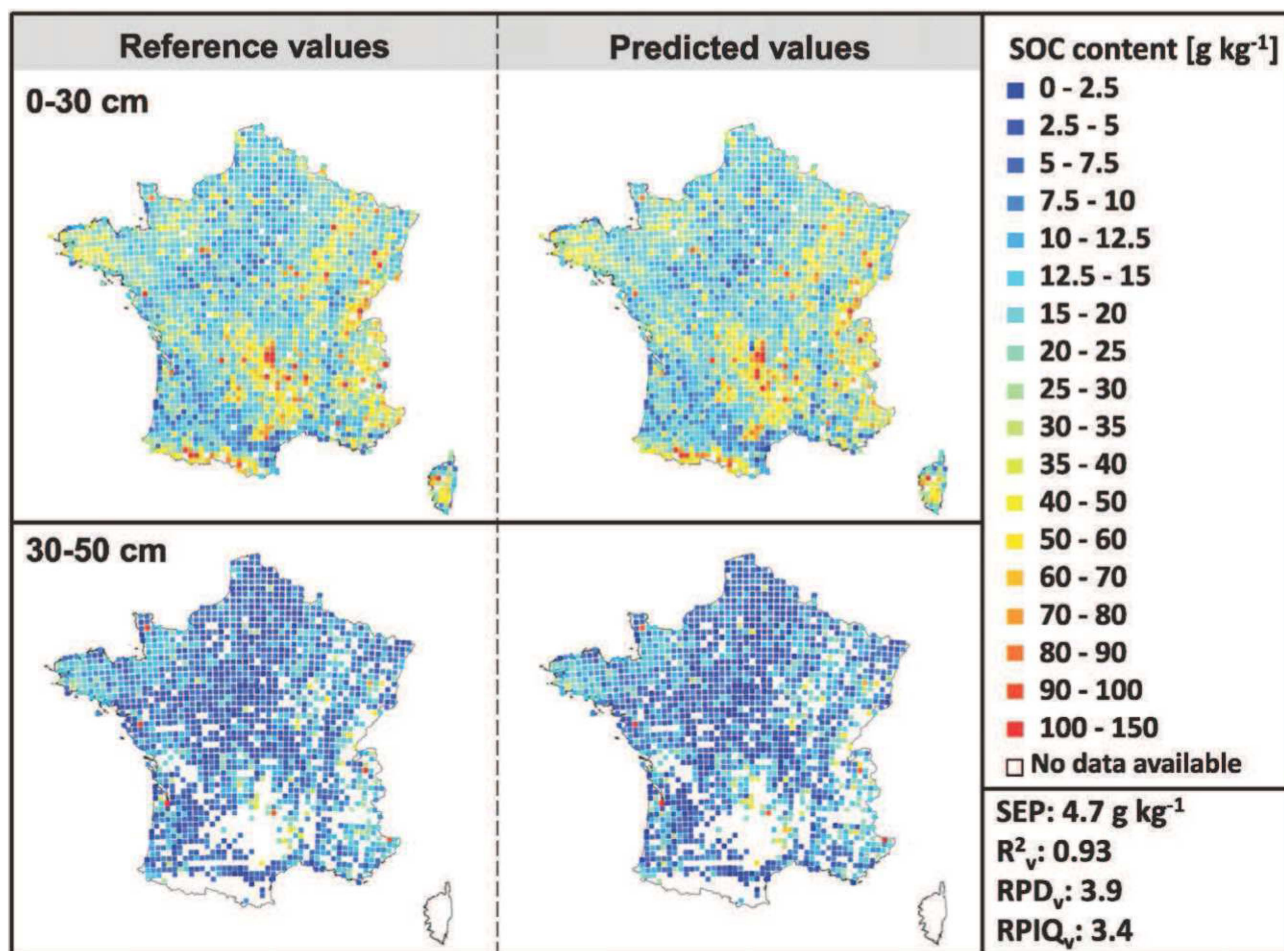


Fig. 7. Maps of SOC content at 0–30 and 30–50 cm depths as measured conventionally (left) and predicted using the MIR spectra (right) and local PLSR leave-one-out cross-validation (thin soils, e.g. in mountain areas, had no 30–50 cm layer, hence blanks in the corresponding regions).

In the best conditions, the present study yielded an accuracy for SOC prediction (SEP) below 2 g kg^{-1} , not far from standard errors of laboratory, which is likely to render DRS more widely acceptable. Indeed, SEP reported in the literature for large database to date are $>3 \text{ g kg}^{-1}$ (e.g. Shepherd and Walsh, 2002; Genot et al., 2011; Gogé et al., 2012; Grinand et al., 2012; Viscarra Rossel and Webster, 2012; Stevens et al., 2013; Shi et al., 2015). It must however be kept in mind that the present study assessed infrared DRS prediction performance under the most favorable conditions, which are rarely met for large spectral libraries: spectra of a given range acquired with the same spectrometer, on finely ground samples ($<0.2 \text{ mm}$); against reference values measured by the same method and same ISO 17025 laboratory.

4. Conclusion

Over the French national soil library, much better predictions were achieved (i) using MIR than NIR or VNIR spectra, (ii) after Kennard-Stone than after random selection of calibration samples, and (iii) using local than global PLS regression. Information contained in each spectral range might explain this ranking, but instrument technology (dispersive system and acquisition mode) might also have an impact. The combination of spectra from different instruments did not improve the results, when compared with MIR spectra alone. Optimal calibration intensity ranged from 30% to 70% and was higher in general with MIR than with NIR or VNIR spectra and with local than global PLSR. However, local PLSR on MIR spectra yielded accurate predictions even using 30% of the calibration samples ($\text{SEP} = 2.6 \text{ g kg}^{-1}$, $\text{RPD} > 2.5$, $\text{RPIQ} > 3$). The most accurate models, using MIR spectra, local PLSR and all calibration samples, allowed SOC content predictions with $\text{SEP} \leq 2 \text{ g kg}^{-1}$, $\text{RPD} > 3$ and $\text{RPIQ} > 4$. These results suggested that laboratory infrared DRS may become a standard method to assess SOC.

Acknowledgements

This work was supported by ADEME (Agence de l'environnement et de la maîtrise de l'énergie, which is a French government agency concerned with environmental protection and energy management; contract 0675C0102). RMQS soil sampling and physico-chemical analyses were supported by the GIS Sol, which is a scientific group of interest on soils involving the French Ministry for ecology and sustainable development and Ministry of agriculture, the French National forest inventory (IFN), ADEME, IRD (Institut de recherche pour le développement, which is a French public research organization dedicated to southern countries) and INRA (Institut national de la recherche agronomique, which is a French public research organization dedicated to agriculture s.l.). The work was also supported by the RIME-PAMPA project funded by AFD (Agence française de développement, which is a French public financial institution dedicated to development assistance to developing countries; contract CZZ3076), the French Ministry for foreign affairs, and the FFEM (Fonds français pour l'environnement mondial, which is a French public funding agency dedicated to environment protection in developing countries). Claudy Jolivet is thanked for his strong involvement in the RMQS monitoring network. Map production assistance was provided by Christina Corbane, who is warmly thanked. Manon Villeneuve, Emmanuel Bourdon, Didier Brunet, Jérôme Lourd, and Clément Robin (IRD) are thanked for their skillful technical assistance and strong investment in the tedious scanning process of the RMQS soil library. Finally, an anonymous reviewer and the editor-in-chief are warmly thanked for their fruitful comments.

References

Arrouays, D., Jolivet, C., Bouillon, L., Bodineau, G., Saby, N., Grolleau, E., 2002. A new initiative in France: a multi-institutional soil quality monitoring network. *Comptes Rendus de l'Académie d'Agriculture de France* 88, 93–105.

Barthès, B.G., Brunet, D., Ferrer, H., Chotte, J.-L., Feller, C., 2006. Determination of total carbon and nitrogen content in a range of tropical soils using near infrared spectroscopy:

influence of replication and sample grinding and drying. *J. Near Infrared Spectrosc.* 14, 341–348.

Batjes, N.H., 1996. Total carbon and nitrogen in the soils of the world. *Eur. J. Soil Sci.* 47, 151–163.

Bellon-Maurel, V., McBratney, A., 2011. Near-infrared (NIR) and mid-infrared (MIR) spectroscopic techniques for assessing the amount of carbon stock in soils – critical review and research perspectives. *Soil Biol. Biochem.* 43, 1398–1410.

Bellon-Maurel, V., Fernandez-Ahumada, E., Palagos, B., Roger, J.-M., McBratney, A., 2010. Critical review of chemometric indicators commonly used for assessing the quality of the prediction of soil attributes by NIR spectroscopy. *Trends Anal. Chem.* 29, 1073–1081.

Ben-Dor, E., Banin, A., 1995. Near-infrared analysis as a rapid method to simultaneously evaluate several soil properties. *Soil Sci. Soc. Am. J.* 59, 364–372.

Ben-Dor, E., Ong, C., Lau, I.C., 2015. Reflectance measurements of soils in the laboratory: standards and protocols. *Geoderma* 245–246, 112–124.

Brown, D.J., Bricklemeyer, R.S., Miller, P.R., 2005. Validation requirements for diffuse reflectance soil characterization models with a case study of VNIR soil C prediction in Montana. *Geoderma* 129, 251–267.

Brunet, D., Barthès, B.G., Chotte, J.-L., Feller, C., 2007. Determination of carbon and nitrogen contents in Alfisols, Oxisols and Ultisols from Africa and Brazil using NIR analysis: effects of sample grinding and set heterogeneity. *Geoderma* 139, 106–117.

Brunet, D., Bernoux, M., Barthès, B.G., 2008. Comparison between predictions of C and N contents in tropical soils using a vis-NIR spectrometer including a fibre-optic probe versus a NIR spectrometer including a sample transport module. *Biosyst. Eng.* 100, 448–452.

Chang, C.-W., Laird, D.A., Mausbach, M.J., Hurburgh, C.R., 2001. Near-infrared reflectance spectroscopy–principal components regression analyses of soil properties. *Soil Sci. Soc. Am. J.* 65, 480–490.

De Brogniez, D., Ballabio, C., Stevens, A., Jones, R.J.A., Montanarella, L., van Wesemael, B., 2015. A map of the topsoil organic carbon content of Europe generated by a generalized additive model. *Eur. J. Soil Sci.* 66, 121–134.

R Development Core Team, 2011. R: A Language and Environment for Statistical Computing. R Found. Stat. Comput. Vienna.

FAO (Food and Agriculture Organization), 2014. World Reference Base for Soil Resources 2014. International Soil Classification System for Naming Soils and Creating Legends for Soil Maps. World Soil Resources Reports 106. FAO, Rome.

Genot, V., Colinet, G., Bock, L., Vanvyve, D., Reusen, Y., Dardenne, P., 2011. Near infrared reflectance spectroscopy for estimating soil characteristics valuable in the diagnosis of soil fertility. *J. Near Infrared Spectrosc.* 19, 117–138.

Gholizadeh, A., Borivka, L., Saberioon, M., Vašát, R., 2013. Visible, near-infrared, and mid-infrared spectroscopy applications for soil assessment with emphasis on soil organic matter content and quality: state-of-the-art and key issues. *Appl. Spectrosc.* 67, 1349–1362.

Gogé, F., Joffre, R., Jolivet, C., Ross, I., Ranjard, L., 2012. Optimization criteria in sample selection step of local regression for quantitative analysis of large soil NIRS database. *Chemometr. Intell. Lab. Syst.* 110, 168–176.

Gras, J.-P., Barthès, B.G., Mahaut, B., Trupin, S., 2014. Best practices for obtaining and processing field visible and near infrared (VNIR) spectra of topsoils. *Geoderma* 214–215, 126–134.

Grinand, C., Barthès, B.G., Brunet, D., Kouakoua, E., Arrouays, D., Jolivet, C., Caria, G., Bernoux, M., 2012. Prediction of soil organic and inorganic carbon contents at a national scale (France) using mid-infrared reflectance spectroscopy (MIRS). *Eur. J. Soil Sci.* 63, 141–151.

ISO (International Organization for Standardisation), 1995a. ISO 10694:1995 – Soil Quality – Determination of Organic and Total Carbon after Dry Combustion (Elementary Analysis). ISO, Geneva.

ISO (International Organization for Standardisation), 1995b. ISO 10693:1995 – Determination of Carbonate Content – Volumetric Method. ISO, Geneva.

Janik, L., Skjemstad, J., 1995. Characterization and analysis of soils using mid-infrared partial least-squares 2. Correlations with some laboratory data. *Aust. J. Soil Res.* 33, 637–650.

Janik, L.J., Skjemstad, J.O., Merry, R.H., 1998. Can mid infrared diffuse reflectance analysis replace soil extractions? *Aust. J. Exp. Agric.* 38, 681–696.

Kennard, R.W., Stone, L.A., 1969. Computer aided design of experiments. *Technometrics* 11, 137–148.

Lal, R., 2004. Soil carbon sequestration impacts on global climate change and food security. *Science* 304, 1623–1627.

Lugato, E., Panagos, P., Bampa, F., Jones, A., Montanarella, L., 2014. A new baseline of organic carbon stock in European agricultural soils using a modelling approach. *Global Soil Biol.* 20, 313–326.

Madari, B.E., Reeves III, J.B., Machado, P.L.O.A., Guimarães, C.M., Torres, E., McCarty, G.W., 2006. Mid- and near-infrared spectroscopic assessment of soil compositional parameters and structural indices in two Ferralsols. *Geoderma* 136, 245–259.

Mark, H.L., Tunnell, D., 1985. Qualitative near-infrared reflectance analysis using Mahalanobis distances. *Anal. Chem.* 57, 1449–1456.


McCarty, G.W., Reeves III, J.B., Reeves, V.B., Follett, R.F., Kimble, J.M., 2002. Mid-infrared and near-infrared diffuse reflectance spectroscopy for soil carbon measurement. *Soil Sci. Soc. Am. J.* 66, 640–646.

Mevik, B.-H., Wehrens, R., 2007. The pls package: principal component and partial least squares regression in R. *J. Stat. Softw.* 18.

Miller, F.A., Wilkins, C.H., 1952. Infrared spectra and characteristic frequencies of inorganic ions. *Anal. Chem.* 24, 1253–1294.


Nocita, M., Stevens, A., van Wesemael, B., Aitkenhead, M., Bachmann, M., Barthès, B., Ben Dor, E., Brown, D.J., Clairotte, M., Csorba, A., Dardenne, P., Demattè, J.A.M., Genot, V., Guerrero, C., Knadel, M., Montanarella, L., Noon, C., Ramirez-Lopez, L., Robertson, J., Sakai, H., Soriano-Disla, J.M., Shepherd, K.D., Stenberg, B., Towett, E.K., Vargas, R., Wetterlind, J., 2015. Soil spectroscopy: an alternative to wet chemistry for soil monitoring. *Adv. Agron.* 132, 139–159.

- Pansu, M., Gautheyrou, J., 2006. Chapter 17 — carbonates. In: *Handbook of Soil Analysis. Mineral, Organic and Inorganic Methods*. Springer, Berlin Heidelberg, Germany, pp. 593–604.
- Pimstein, A., Notesco, G., Ben-Dor, E., 2011. Performance of three identical spectrometers in retrieving soil reflectance under laboratory conditions. *Soil Sci. Soc. Am. J.* 75, 746–759.
- Rabenarivo, M., Chapuis-Lardy, L., Brunet, D., Chotte, J.-L., Rabeharisoa, L., Barthès, B.G., 2013. Comparing near and mid-infrared reflectance spectroscopy for determining properties of Malagasy soils, using global or LOCAL calibration. *J. Near Infrared Spectrosc.* 21, 495–509.
- Ramirez-Lopez, L., Behrens, T., Schmidt, K., Stevens, A., Demattê, J.A.M., Scholten, T., 2013b. The spectrum-based learner: a new local approach for modeling soil vis-NIR spectra of complex datasets. *Geoderma* 195–196, 268–279.
- Ramirez-Lopez, L., Behrens, T., Schmidt, K., Viscarra Rossel, R.A., Demattê, J.A.M., Scholten, T., 2013a. Distance and similarity-search metrics for use with soil vis-NIR spectra. *Geoderma* 199, 43–53.
- Reeves, D.W., 1997. The role of soil organic matter in maintaining soil quality in continuous cropping systems. *Soil Tillage Res.* 43, 131–167.
- Reeves III, J.B., 2010. Near- versus mid-infrared diffuse reflectance spectroscopy for soil analysis emphasizing carbon and laboratory versus on-site analysis: where are we and what needs to be done? *Geoderma* 158, 3–14.
- Schils, R., Kuikman, P., Liski, J., van Oijen, M., Smith, P., Webb, J., Alm, J., Somogyi, Z., van den Akker, J., Billett, M., Emmett, B., Evans, C., Lindner, M., Palosuo, T., Bellamy, P., Alm, J., Jandl, R., Hiederer, R., 2008. Review of Existing Information on the Interrelations Between Soil and Climate Change CLIMSOIL. Technical Report 2008–048. Wageningen UR, the Netherlands.
- Shenk, J.S., Westerhaus, M.O., 1991. Populations structuring of near infrared spectra and modified partial least squares regression. *Crop Sci.* 31, 1548–1555.
- Shenk, J., Westerhaus, M., Berzaghi, P., 1997. Investigation of a LOCAL calibration procedure for near infrared instruments. *J. Near Infrared Spectrosc.* 5, 223–232.
- Shepherd, K.D., Walsh, M.G., 2002. Development of reflectance spectral libraries for characterization of soil properties. *Soil Sci. Soc. Am. J.* 66, 988–998.
- Shi, Z., Ji, W., Viscarra Rossel, R.A., Chen, S., Zhou, Y., 2015. Prediction of soil organic matter using a spatially constrained local partial least squares regression and the Chinese vis-NIR spectral library. *Eur. J. Soil Sci.* 66, 679–687.
- Soriano-Disla, J.M., Janik, L.J., Viscarra Rossel, R.A., Macdonald, L.M., McLaughlin, M.J., 2014. The performance of visible, near-, and mid-infrared reflectance spectroscopy for prediction of soil physical, chemical, and biological properties. *Appl. Spectrosc. Rev.* 49, 139–186.
- Stevens, A., Ramirez-Lopez, L., 2013. An Introduction to the Prospector Package (R Package Vignette).
- Stevens, A., Nocita, M., Tóth, G., Montanarella, L., van Wesemael, B., 2013. Prediction of soil organic carbon at the European scale by visible and near infrared reflectance spectroscopy. *PLoS One* 8, e66409.
- USDA (United States Department of Agriculture), 2013. Rapid Carbon Assessment (RaCA) Methodology Sampling and Initial Summary. USDA, National Resources Conservation Service, National Soil Survey Center, Lincoln, NE, USA.
- van Reeuwijk, L.P., 1992. Procedures for Soil Analysis. International Soil Reference and Information Centre, Wageningen, the Netherlands.
- Vasques, G.M., Grunwald, S., Sickman, J.O., 2008. Comparison of multivariate methods for inferential modeling of soil carbon using visible/near-infrared spectra. *Geoderma* 146, 14–25.
- Vaughan, D., Malcolm, R.E., 1985. *Soil Organic Matter and Biological Activity*. Springer Netherlands, Dordrecht.
- Viscarra Rossel, R.A., Webster, R., 2012. Predicting soil properties from the Australian soil visible-near infrared spectroscopic database. *Eur. J. Soil Sci.* 63, 848–860.
- Viscarra Rossel, R.A., Walvoort, D.J.J., McBratney, A.B., Janik, L.J., Skjemstad, J.O., 2006. Visible, near infrared, mid infrared or combined diffuse reflectance spectroscopy for simultaneous assessment of various soil properties. *Geoderma* 131, 59–75.
- Vohland, M., Ludwig, M., Thiele-Bruhn, S., Ludwig, B., 2014. Determination of soil properties with visible to near- and mid-infrared spectroscopy: effects of spectral variable selection. *Geoderma* 223–225, 88–96.
- Workman Jr., J., Weyer, L., 2008. *Practical Guide to Interpretive Near-Infrared Spectroscopy*. CRC Press, Boca Raton, FL, USA.
- Zhang, M., Xu, Q., Massart, D., 2004. Averaged and weighted average partial least squares. *Anal. Chim. Acta* 504, 279–289.



Contents lists available at ScienceDirect

Geoderma Regional

journal homepage: www.elsevier.com/locate/geodrs

Mapping soil organic carbon on a national scale: Towards an improved and updated map of Madagascar

Nandrianina Ramifehiarivo^a, Michel Brossard^b, Clovis Grinand^c, Andry Andriamananjara^a, Tantely Razafimbelo^a, Andriambolantsoa Rasolohery^d, Hery Razafimahatratra^e, Frédérique Seyler^f, Ntsoa Ranaivoson^a, Michel Rabenarivo^a, Alain Albrecht^g, Franck Razafindrabe^h, Herintsitohaina Razakamanarivo^{a,*}

^a Laboratoire des Radioisotopes, BP 3383 Route d'Andraisoro, 101 Antananarivo, Madagascar

^b UMR ECO&SOLS, c/o IRD, BP 90165, 97323 Cayenne cedex, France

^c Association Etc Terra, Lot VE 26 L. Ambanidia, 101 Antananarivo, Madagascar

^d Conservation International Madagascar, Lot II W 27D Rue Vittori François Ankorahotra, 101 Antananarivo, Madagascar

^e Ecole Supérieure des Sciences Agronomiques, BP 175 Université d'Antananarivo Ankato, 101 Antananarivo, Madagascar

^f UMR ESPACE-DEV, IRD, Maison de la Télédétection, 500 rue Jean-François Breton, 34093 Montpellier Cedex 5, France

^g UMR ECO&SOLS IRD, Campus SupAgro, place Viala, 34060 Montpellier Cedex 1, France

^h FTM Institut Géographique de Madagascar, BP 323 Ambanidia, 101 Antananarivo, Madagascar

ARTICLE INFO

Article history:

Received 20 June 2016

Received in revised form 6 October 2016

Accepted 16 December 2016

Available online xxxx

Keywords:

Digital soil mapping

Modelling

Soil database

Soil fertility

Tropical soil

Ferralsols, Andosols

Luvisols

Fluvisols

Histosols

Leptosols

Cambisols

Podzols

Vertisols

Alisols

Nitisols

Regosols

Arenosols

ABSTRACT

Assessment of soil organic carbon stocks (SOC_s) is highly relevant considering that SOC_s is the central driver in climate change mitigation and soil fertility. In Madagascar, a first attempt at mapping SOC_s on a national scale was undertaken in 2009 with previous soil data. Advanced research on soil carbon mapping on a global scale is required to enable better land use decisions. This study aims to (i) evaluate the drivers of soil organic carbon (SOC) storage in the first 30 cm soil layer on a national scale from spatially explicit explanatory environmental variables and a recent soil database and (ii) update the spatial distribution of SOC_s at this scale through digital mapping. A spatial model was established using randomForest, a decision tree algorithm and based on 10 pedoclimatic, topographic, and vegetation variables. The model was developed with 1993 available soil plot data (collected from 2010 to 2015) and their environmental information ("VALSOL-Madagascar" database). These data were divided into two sets: a first set (n = 835) used for model calibration and a second set (n = 358) for external validation. Results showed that mean annual temperature (MAT, °C), mean annual precipitation (MAP, mm), elevation (m) and Normalized Difference Vegetation Index (NDVI) were the most important predictors of SOC_s. The retained prediction model had a Root Mean Squared Error (RMSE) equal to 25.8 MgC·ha⁻¹. The predicted SOC_s from fitted models ranged from 28 to 198 MgC·ha⁻¹ with total SOC_s to 4137 TgC. Depending on soil type, Ferralsols (35 to 165 MgC·ha⁻¹) and Andosols (48 to 198 MgC·ha⁻¹) had relevant results related to the number of soil profiles (n = 856 and 171 respectively). Despite the need for in-depth analysis, the model and map produced in the present study has greatly improved our knowledge of the spatial distribution of SOC_s in Madagascar and reduced uncertainty compared to the former map. This map provides new perspectives in sustainable land management in Madagascar.

© 2016 Elsevier B.V. All rights reserved.

* Corresponding author.

E-mail addresses: ranandrianina@hotmail.fr (N. Ramifehiarivo), michel.brossard@ird.fr (M. Brossard), c.grinand@etcterra.org (C. Grinand), njaraandry1@gmail.com (A. Andriamananjara), tantely.razafimbelo@gmail.com (T. Razafimbelo), arasolohery@conservation.org (A. Rasolohery), hery_razafimahatratra@yahoo.fr (H. Razafimahatratra), frederique.seyler@ird.fr (F. Seyler), sabotsy27@yahoo.fr (N. Ranaivoson), miarabenarivo@yahoo.fr (M. Rabenarivo), alain.albrecht@ird.fr (A. Albrecht), dgftm@moov.mg (F. Razafindrabe), herintsitohaina.razakamanarivo@gmail.com (H. Razakamanarivo).

1. Introduction

Soils provide numerous ecosystem services but changes in land use and climate have affected their properties and functions (Millennium Ecosystem Assessment, 2005). Among these services, soil contains the largest pool of organic carbon in terrestrial ecosystems including forests, grasslands, agroecosystems and others (Batjes, 1996; Bolin et al., 2001; Matsuura et al., 2012; White et al., 2000).

<http://dx.doi.org/10.1016/j.geodrs.2016.12.002>

2352-0094/© 2016 Elsevier B.V. All rights reserved.

Please cite this article as: Ramifehiarivo, N., et al., Mapping soil organic carbon on a national scale: Towards an improved and updated map of Madagascar, (2016), <http://dx.doi.org/10.1016/j.geodrs.2016.12.002>

Soil organic carbon (SOC) maintains soil health and productivity of plant resources. It provides a primary source of nutrients for plants, helps particle aggregation and porosity promoting soil structure, increases water storage capacity and availability for plants, protects soil from erosion and provides a habitat for soil biota (Rossel et al., 2016). Carbon sequestration in soils can improve the quality and productivity of the soil to sustain food production and simultaneously mitigate emissions of greenhouse gases (GHG). Thus, soils have a huge potential for either sequestering or releasing carbon into the atmosphere (Kutsch et al., 2009).

Better understanding of ecosystem carbon balance is crucial for predicting carbon-climate feedback and guiding the implementation of mitigation policies (Fang et al., 2014; McKinley et al., 2011; Pan et al., 2011). Information about soil properties such as soil organic carbon stocks (SOC_s) could be very helpful in addressing climatic and environmental degradation issues and justifying SOC_s mapping.

Digital Soil Mapping techniques can potentially produce information about soil properties that are not currently available (Hempel et al., 2005; Legros, 2006). Moreover, they improve the consistency, accuracy, detail and speed at which soil survey information is produced. These techniques can be used both to update existing soil survey information and create information in unmapped areas (Lagacherie, 2007). In addition, a spatial soil information system created by a numerical model based on soil information and related environmental variables could account for spatial and temporal variations in soil properties (Lagacherie and McBratney, 2007).

In Madagascar, several attempts were made at mapping SOC_s on different scales. Locally, Razakamanarivo et al. (2011) mapped SOC_s for the first 30 cm depth in eucalyptus plantations in the central highlands of Madagascar by using multiple regression approaches. Grinand et al. (2009) produced a SOC_s map for the 30 cm top soil layer according to land uses and soil information at national scale. The authors used a georeferenced soil database named VALSOL-Madagascar (Beaudou and Le Martret, 2004) which gathered soil inventory data collected from 1946 to 1979. This first evaluation of organic carbon resource in Madagascar is however at coarse resolution (1 km) and display SOC_s levels that were observed more than thirty years ago. Considering the high rate of land use change especially related to deforestation (Harper et al., 2007) and unsustainable agricultural practices (Vagen et al., 2006), digital SOC_s mapping is urgently needed in Madagascar, in order to reduce uncertainty at large scale, whilst improving the spatial resolution of the estimates. The map uncertainties are related to small sample size, uneven plot location, errors generated from laboratory analysis and land cover mapping from remote sensing. In 2015, the VALSOL-Madagascar database was updated and ongoing research is focusing on improving SOC_s maps on different scales by testing various digital spatial models (e.g.: randomForest, linear regression model, linear mixed effects models) combining large spatially-explicit environmental database with the most recent soil data.

The present study aimed to produce a national SOC_s map using the most recent soil information and relevant covariates explaining the SOC_s distribution. The main objectives of this paper were (i) to identify relevant factors controlling SOC_s (0–30 cm depth) (ii) to produce an improved national SOC_s map by using an updated soil database and digital soil mapping techniques.

2. Materials and methods

2.1. Study area

Madagascar is an island located in Eastern Africa in the Indian Ocean (between 11°57 and 25°29 South and 43°14 and 50°27 East) with a total surface area of 587,000 km². It has a unimodal tropical climate characterized by a wide climate gradients and vegetation changes (Styger et al., 2009). With an average of 7 dry season months, precipitation range from 500 to 3200 mm and temperature from 13 to 27 °C.

According to the soil map produced by Delenne and Pelletier (1980), Madagascar soil cover includes 11 soil types. Dominant soil types are Ferrallitic soils (Ferrasols, FAO, 2014) and Ferruginous soils (Ferric Luvisols, FAO, 2014) covering over 46% and 28% of national area respectively (Grinand et al., 2009) (Fig. 1).

2.2. Soil organic carbon stock database

In this study, 1193 soil plots dated from 2010 till 2015 were gathered and added in the national VALSOL-Madagascar database which is the only existing georeferenced soil database in Madagascar. These new data come from fourteen agronomical and environmental studies conducted throughout the country by LRI team and partners (Table 1). The VALSOL-Madagascar database was first established in 1980 and includes physical and chemical data on Malagasy soils gathered from old soil surveys carried out by the French Institute of Research for Development (IRD, previously called ORSTOM) between 1946 and 1979 (Leprun et al., 2010). VALSOL-Madagascar is currently being maintained through a close collaboration between the “Laboratoire des Radiosotopes” (LRI) University of Antananarivo in Madagascar and the IRD. The updated soil database record soil information by vertical profile including geographical location, physical and chemical soil properties such as soil thickness, soil organic carbon content, bulk density, and soil texture (clay, silt and sand content). This available legacy soil data and information was harmonized for each plots in order to calculate SOC_s and to map spatial distribution of SOC_s in 0–30 cm depth similarly to other studies (Bernoux et al., 2002; Martin et al., 2011; Minasny et al., 2013; Nussbaum et al., 2014).

2.3. Calculation of soil organic carbon stocks

The SOC_s per soil profile in MgC·ha^{−1} were calculated using soil bulk density methods (Chapuis-Lardy et al., 2002; Razafimbelo et al., 2008; Razakamanarivo et al., 2011) and the carbon content was estimated using conventional Walkley and Black (1934) methods or combined with an alternative method using mid infrared spectroscopy (MIRS) analysis (Reeves, 2010). The calculation for each profile with k layers was performed as follows (Eq. (1)):

$$\text{SOC}_s = \sum_{i=1}^k [\text{CCi} \times \text{BDi} \times \text{Di} \times (1 - \text{CFi})] \quad (1)$$

where SOC_s is the total amount of soil organic carbon per unit area (MgC·ha^{−1}), CCi is the concentration of soil organic carbon in layer i (gC·kg^{−1}), BDi is the bulk density (g·cm^{−3}) of layer i , Di is the thickness of layer i (m), and CFi is the fraction of the volume of coarse fragments >2 mm in layer i (with $0 \leq \text{CFi} < 1$) (Batjes, 1996; Matsuura et al., 2012; Penman et al., 2003). For each soil profile, the SOC_s per unit area was calculated for a depth of 0–30 cm (3 layers: 0–10 cm, 10–20 cm and 20–30 cm).

2.4. Collection and harmonization of spatially-explicit covariates

In order to predict SOC_s, we considered potential, easy access and commonly used explanatory spatial variables (Table 2) (Grunwald, 2009; McBratney et al., 2003), that were either categorical dataset such as soil map and land-cover map, or continuous such as climate, topography, tree cover and satellite data.

Each available spatial data described below, were projected in the same spatial reference system (WGS84/UTM 38S) and resampled at 30 m × 30 m resolution which is the ground resolution considered appropriate for 1/100,000 scale mapping purpose (Legros, 2006). Explanatory variable values were extracted on each soil profile using GIS tools (QGIS software 2.6., 2014).

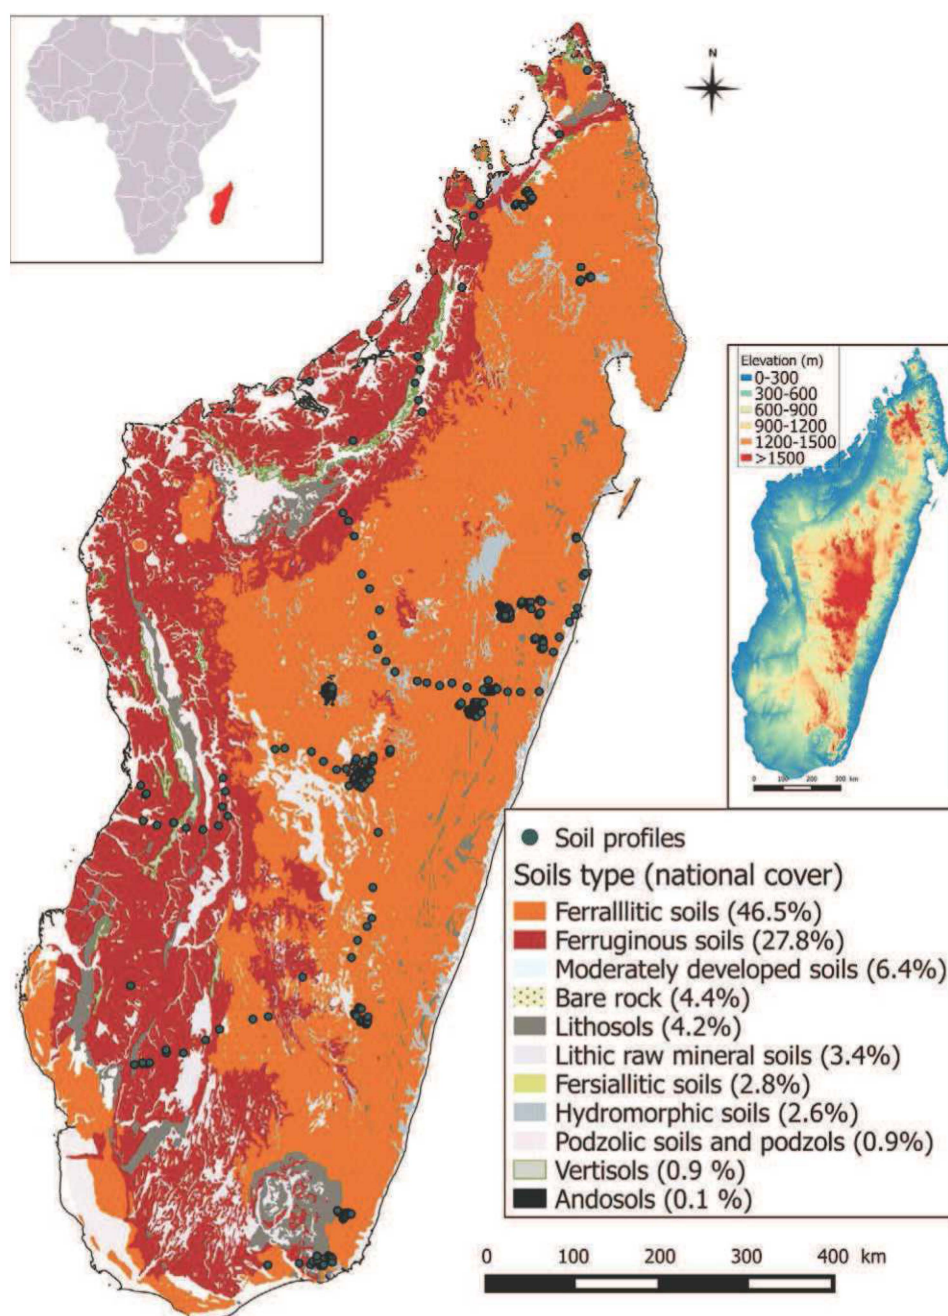


Fig. 1. Soil distribution in Madagascar (Delenne and Pelletier, 1980) with location of the 1193 soil profiles in VALSOL-Madagascar database.

Table 1

Descriptive statistics of SOC_s (MgC·ha⁻¹) in VALSOL-Madagascar and Grinand et al. (2009) according to soil type by Delenne and Pelletier (1980) and corresponding to FAO (2014).

	Soil type	Soil type according to FAO (2014)	VALSOL-Madagascar					Grinand et al. (2009)				
			n	Mean	Min	Max	CV	n	Mean	Min	Max	CV
1	Ferrallitic soils	Ferralsols	856	88.3	16.8	232.8	0.39	89	61.3	5	163.2	0.62
2	Andosols	Andosols	171	117.5	22.7	225.7	0.45	4	90.8	62.1	120.3	0.36
3	Ferruginous soils	Ferric Luvisols	57	66.5	16.6	209.2	0.59	50	33.6	3.6	86.2	0.63
4	Hydromorphic soils	Fluvisols/histosols	51	87.6	18.8	177.9	0.34	40	75.9	9.9	161.1	0.49
5	Lithosols	Lithic Leptosols	44	82.7	13.7	157.6	0.48	4	33.6	21.4	52.5	0.40
6	Moderately developed soils	Cambisols	7	43.3	16.8	55.2	0.31	33	53.2	12.3	198.8	0.76
7	Podzolic soils and podzols	Podzols	3	52.6	18.8	78.9	0.58	1	66.6			
8	Vertisols	Vertisols	2	45.1	41.5	48.8	0.12	7	47.7	18.1	80.4	0.52
9	Fersiallitic soils	Alisols/nitisols	1	46.0	–	–	–	8	32.5	13.1	74.6	0.63
10	Bare rock	–	1	49.2	–	–	–					
11	Lithic raw mineral soils	Regosols/leptosols/arenosols	–	–	–	–	–	12	18.8	1.2	46.1	0.69
Total			1193	90.7	13.7	232.8	0.44	279	1.2	1.2	198.8	–

Table 2
Characteristics and statistics of SOC_s of predictor variables.

Type	Name (code name)	Unit	Type	Mean	Min.	Max.
Topography data	Elevation (Elevation)	m	Cont.	887	11	2121
	Slope (Slope)	%	Cont.	9.23	0.11	37.1
Climate data	Mean Annual Precipitation (MAP)	mm	Cont.	1586	554	3203
	Mean Annual Temperature (MAT)	°C	Cont.	20.2	13.2	27
Satellite derived data	Normalized Difference Vegetation Index (NDVI)		Cont.	0.56	−0.08	0.97
	Normalized Difference Water Index (NDWI)		Cont.	0.07	−0.37	0.43
	Normalized InfraRed Index (NIRI)		Cont.	−0.07	−0.43	−0.07
Vegetation data	Tree cover map (Tree_cover)	%	Cont.	60.13	0	100
	Land cover (Land_cover)		Disc	9 classes ^a		
Soil map	Soil type (Soil)		Disc.	11 classes ^b		

Cont.: continuous/quantitative data Disc.: categorical data.

^a Cultivated areas, North Western dry forest, Wooded grassland/bushland mosaic, Grassland/wooded grassland mosaic, Western dry forest, Eastern humid forest, South Western dry spiny forest/thicket, degraded eastern humid forest, South western subhumid forest.^b Ferrallitic soils, Ferruginous soils, Moderately developed soils, Bare rock, Lithosols, Lithic raw mineral soils, Fersiallitic soils, Hydromorphic soils, Podzolic soils and podzols, Vertisols, Andosol.

2.4.1. National soil map

Delenne and Pelletier (1980) soil map is still the most national soil map and has been used in the present study (Fig. 1). It was developed using a modified classification of French Commission of Soil Science and Soil Mapping (CPCS, 1967) and adapted to the local context (Grinand et al., 2009). The classification system includes 11 soil types based on detailed descriptions of soil formation processes and profile characters (Duchaufour, 1998). The most extensive area according to soil type (74%) is occupied by Ferralsols (Ferrallitic soils) and Ferric Luvisols (Ferruginous soils), other cartographic units represent <10% of the area of the country. Table 1 presents SOC_s data distribution according to the previous soil map (Delenne and Pelletier, 1980) with the corresponding soil type following the Word Reference database for soil resources (FAO, 2014).

2.4.2. Land use and land cover

Vegetation data includes two sources of dataset. The first is a land-cover map (Land_cover) showing vegetation distribution derived from MODIS and Landsat 7 satellites at 30 m × 30 m of spatial resolution (Moat and Smith, 2007). The second is the Tree cover map (Tree_Cover) representing the percentage of tree cover within a 30 m pixel for the year 2000 derived from Landsat images (Hansen et al., 2013).

2.4.3. Climate

The climate dataset considered were: (i) mean annual precipitation (MAP, mm) and (ii) mean annual temperature (MAT, °C). They were derived from the WorldClim database which gather high resolution (1 km) climate dataset worldwide (Hijmans et al., 2005).

2.4.4. Topography

Topography dataset came from the digital elevation model provided by the French national geographic institute (IGN). Topographic data with a resolution of 90 m × 90 m is: Elevation (m) (Fig. 1), and Slope (%). Slope data was calculated on QGIS software (QGIS, 2014) using the elevation map (CNES, 2014).

2.4.5. Other soil and vegetation dataset

We used the 2014 Landsat cloud-free images composite (Hansen et al., 2013) to derive the soil and vegetation indexes: (i) Normalized Difference Vegetation Index (NDVI) map (Eq. (2)), (ii) Normalized InfraRed Index (NIRI) map (Eq. (3)) and (iii) Normalized Difference Water Index (NDWI) (Eq. (4)) by Gao (1996). NDVI was used as a potential indicator for growth and vigour of vegetation (Rouse et al., 1974). As NDVI saturates for vegetation with high greenness, NIRI and NDWI were also used. NIRI and NDWI are less prone to saturation (Mustafa et al., 2010) hence more appropriate for the humid tropical forest in the Eastern part of the island. They were considered also as a

proxy of soil water content and ferrous oxide content which are strong indicator of soil types. Hereafter the formulas which were used to calculate these indices:

$$\text{NDVI} = (\text{NIR} - \text{R}) / (\text{NIR} + \text{R}) \quad (2)$$

$$\text{NIRI} = (\text{R} - \text{NIR}) / (\text{SWIR} + \text{NIR}) \quad (3)$$

$$\text{NDWI} = (\text{NIR} - \text{SWIR}) / (\text{SWIR} + \text{NIR}) \quad (4)$$

where NIR is the Near infrared band, R the Red band, SWIR the Shortwave Infrared band and G the Green band.

2.5. Soil organic carbon modelling

Spatially explicit SOC_s estimation was developed using the randomForest (RF, Breiman, 2001) algorithm. RF is a machine-learning algorithm that extends standard classification and regression tree (CART) methods by creating a collection of small classification trees (Wei et al., 2010). Unlike traditional CART analyses, the fit of each tree is assessed using randomly selected cases (1/3 of the data), which are withheld during its construction (out-of-bag or OOB sample).

The application of RF in the field of soil science is relatively recent but it is a potentially powerful approach for modelling in various soil-landscape regions and scales (Grimm et al., 2008; Grinand et al., 2017; Kim et al., 2012; Vagen et al., 2016). This model was also proved to provide accurate soil properties at continental scale (Hengl et al., 2015).

The whole 1193 SOC_s dataset were randomly divided into 2 sets: one for calibration (70% of the population $n = 835$) and one set for external validation (30% of the population $n = 358$). Once the model was created and validated, it was applied to the whole study area for the spatialisation.

RF modelling was performed using the randomForest package in R software (R.3.2.2).

2.6. Model evaluation

The quality of the model was evaluated by predicting the SOC_s values for the 30% sample data which is not used in the mapping exercise and by computing the R-squared (R^2 , coefficient of determination) and the RMSE (Root Mean Squared Error ($\text{MgC} \cdot \text{ha}^{-1}$)). The more R^2 is close to 1 and the lower RMSE is, the better and more robust the model is (Delmas et al., 2015; Hastie et al., 2009; Suuster et al., 2012). For this study, all of the variables were input for the randomForest model.

RMSE was calculated as follows (Eq. (5)).

$$\text{RMSE} = \sqrt{\sum [(d_i - p_i)^2 / n]} \quad (5)$$

where n was the number of observations in the external validation dataset, d_i was the observed SOC_s value, p_i was the predicted SOC_s value.

2.7. Relative importance of variables

RF provides a mean to assess the relative importance of predictors using two different metrics. Here, we used the Increased Mean Standard Error (%IncMSE). This metric is obtained by computing the difference between the OOB error of the calibrated tree model and after permuting each predictor variable (~random model), averaged and normalized over all the trees.

The most relevant variables in the model were further analysed using the VSURF package (Variable Selected Using randomForests). It is achieved by gradually adding variables to the model and picking the version of the model with the lowest Out Of Bag error (Breiman, 2001). The VSURF package returns two subsets of variables: the first is a subset of important variables including some redundancy which can be relevant for interpretation and the second is a smaller subset corresponding to a version of the model that tries to avoid redundancy and focuses more closely on the prediction objective (Genuer et al., 2014).

2.8. Verification of the accuracy of the map

The SOC_s map produced in the present was compared to the previous SOC_s map established by Grinand et al. (2009) and compared with reference dataset. We analysed the (i) SOC_s mean and range per soil type at country level, (ii) the overall SOC_s amount computing the SOC_s mean and total pixel area, and (iii) the SOC distribution and quality of each map. The latter was carried out at a local scale with the County of Didy, Ambatondrazaka District in the Eastern region of Madagascar. This county was selected for how representativeness of its SOC_s data was when compared to the average number for other counties. In order to test the accuracy of the newly produced map compared to the oldest available one, 1365 random points was created in this area by using QGIS, and the values of the prediction of each map was compared. Also, the limit of the produced map was verified by considering: the distribution of predicted pixel according to SOC_s values, the used resolution of spatial predictor variables, and the representativeness of sampling points in time and in space.

3. Results

3.1. Spatial model

The best fit model obtained showed a $R^2 = 0.59$ and a RMSE = $25.8 \text{ MgC}\cdot\text{ha}^{-1}$ (Fig. 2). This model tends to underestimate SOC_s values higher than $150 \text{ MgC}\cdot\text{ha}^{-1}$ and overestimate SOC_s values below $50 \text{ MgC}\cdot\text{ha}^{-1}$ (Fig. 2).

According to the VSURF package all predictive variables were important for the model's construction, but the most relevant, with the highest relative importance index (%IncMSE) were: MAP, Elevation, MAT and NDVI. The %IncMSE of MAP-MAT-Elevation and NDVI were 741–712–693 and 327 respectively; which is higher than the %IncMSE values of the other factors such as NRI-NDWI-Soil-Tree cover-Land cover and Slope (300–294–233–220–186 and 150 respectively) (Fig. 3).

3.2. Digital SOC_s maps and their variability

A map of SOC_s in the first 30 cm soil layer at national level was produced by using the best fit model (Fig. 4 and Table 3). SOC_s values from the produced map ranged from 28.3 to $197.6 \text{ MgC}\cdot\text{ha}^{-1}$. For the whole country, the SOC_s total were $4137 \pm 1214 \text{ TgC}$ with a variation coefficient of 0.29. There were some gaps in regions with lithic raw mineral soils because of the inexistence of our SOC_s database and 3.4% of the area was not predicted.




Fig. 2. External validation procedure results considering our best fit model.

In any case, according to soil type (Table 3), SOC_s values varied from 35.4 to $165.1 \text{ MgC}\cdot\text{ha}^{-1}$ in Ferralsol soils, 47.3 to $197.6 \text{ MgC}\cdot\text{ha}^{-1}$ in Andosols soils, 28.3 to $144.3 \text{ MgC}\cdot\text{ha}^{-1}$ in Ferric Luvisols (Ferruginous soil), 38.2 to $156.8 \text{ MgC}\cdot\text{ha}^{-1}$ in Fluvisols (Hydromorphic soils) and 62.9 to $145.8 \text{ MgC}\cdot\text{ha}^{-1}$ in Lithosols (Lithic Leptosols). These soil types cover 81% of the area of Madagascar and were the most represented in our point sample dataset.

3.3. Comparison with existing SOC_s map

The total of SOC_s for Grinand et al. (2009) was $2583 \pm 1565 \text{ TgC}$ ($\text{CV} = 0.66$), less than the results presented in this study. This difference can be explained by the lowest mean of SOC_s and the lowest number of soil profiles used for the mapping area occupied by the Ferralsol area (mean = $61.3 \text{ MgC}\cdot\text{ha}^{-1}$, $n = 89$) and Ferric Luvisol area (mean = $33.6 \text{ MgC}\cdot\text{ha}^{-1}$, $n = 50$) which are the dominant soils in Madagascar (Table 1).




Fig. 3. Relative importance of variables.

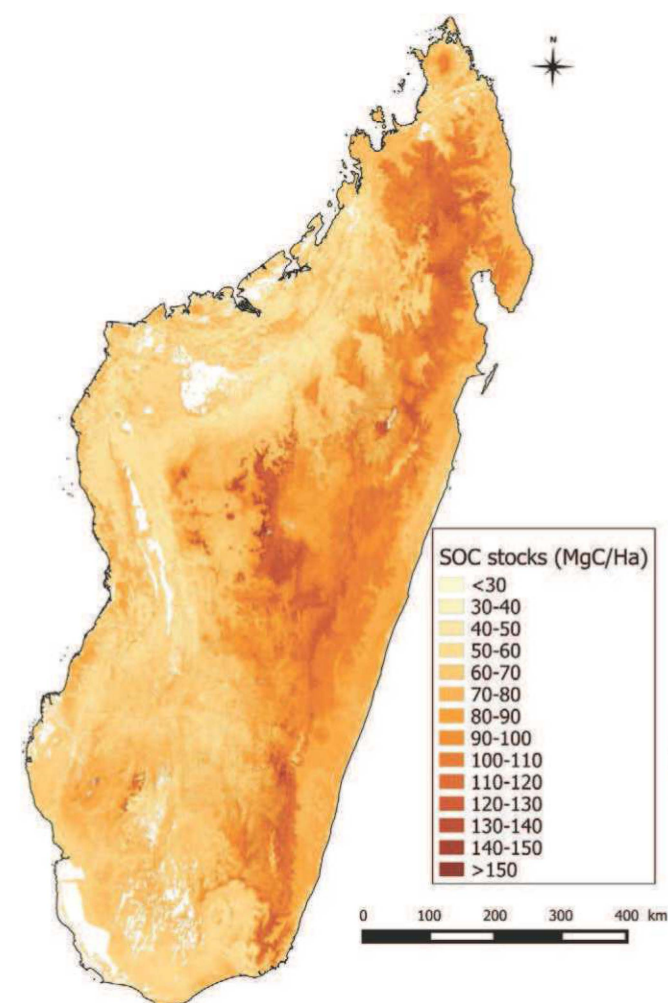


Fig. 4. SOC_s (MgC·ha⁻¹) distribution map at national scale for the first 30 cm soil layer based on predicted SOC_s obtained by the use of spatial model generated by the randomForest algorithm.

In the county of Didy, Fig. 5 showed that the prediction of the two maps for the 1365 random points was different. The oldest map gave only eight values, compared to the new map. There was also a lot of non-predicted pixel compared to the actual maps. Grinand et al. (2009) used the average of SOC_s values for soil type and vegetation unit, and there is no change in SOC_s within the same map unit (Figs. 6 & 7). Our predictive model computes the value of each map pixel in accordance with the values of each variable in the regression trees.

Table 3
Descriptive statistics of SOC_s (MgC·ha⁻¹) for soil types (Delenne and Pelletier, 1980) according the newly produced national digital map.

	Soil type	Soil type according to FAO (2014)	n	Mean	Min	Max	CV
1	Ferrallitic soils	Ferralsols	592	81.0	35.4	165.1	0.24
2	Andosols	Andosols	126	116.4	47.3	197.6	0.25
3	Ferruginous soils	Ferric Luvisols	41	57.1	28.3	144.3	0.22
4	Hydromorphic soils	Fluvisols/histosols	31	81.3	38.2	156.8	0.22
5	Lithosols	Lithic Leptosols	34	62.9	34.6	145.8	0.27
6	Moderately developed soils	Cambisols	5	55.4	32.2	120.5	0.17
7	Podzolic soils and podzols	Podzols	2	61.0	34.4	128.3	0.11
8	Vertisols	Vertisols	2	54.8	32.7	92.1	0.18
9	Fersiallitic soils	Alisols/nitisols	1	60.4	36.3	123.9	0.12
10	Bare rock	–	1	75.4	35.4	154.5	0.28
11	Lithic raw mineral soils	Regosols/leptosols/arenosols					
TOTAL			835	71.1	28.3	197.6	0.29

n as number of SOC_s used on calibration model.

4. Discussion

4.1. Relevant predictor variables of soil organic carbon stocks

Results of the prediction method showed that the spatial distribution of SOC_s is driven by a combination of elevation, climate and vegetation data (Fig. 3). The importance of these predictor variables differed according to the model. Precipitation, temperature, elevation and soil-vegetation index largely influenced the spatial distribution of SOC_s. These results were expected, as precipitation and temperature have a strong effect on Soil Organic Matter (SOM) decomposition (Grace et al., 2006).

Modelling of soil organic carbon by Were et al. (2016) showed that elevation was important for predicting SOC_s with other data such as silt content and satellite band. Indeed, in tropical soils, organic matter increases with precipitation, lower temperatures and elevation (Wang et al., 2013). Previous work reported that humidity and temperature decreased with altitude and these variables are the main factors behind the low rate of decomposition of SOM and thus the accumulation of SOC at higher elevation. Conversely, the speed of decomposition of organic matter increases with temperature, humidity and the oxygen content of soil (Wang et al., 2010). Also, organic material in the soil is essentially derived from residual plant and animal material due to the action of decomposition by microbes under the influence of temperature, moisture and ambient soil conditions (Yigini and Panagos, 2014).

A study by Sreenivas et al. (2014) found that NDVI and land cover were significant variables for predicting SOC_s on a model using climate data, NDVI, land-cover type, soil type and topography datasets ($R^2 = 0.86$). NDVI highlighted the vegetation percentage cover and the presence of vegetation in the area (Rouse et al., 1974). SOC_s result from the balance between inputs and outputs of carbon in the soil (Davidson and Janssens, 2006). Vegetation such as plant debris and roots from biomass are the “inputs”, while the outputs are dominated by CO₂ flux of soil and methane (CH₄). Additionally, vegetation is strongly linked to the presence or absence of human activity in the area. Indeed, carbon mineralization of the soil depended on the changes in vegetation cover that are often modified by human activity (Martin et al., 2010). SOC_s is usually high in natural environments and decreases with land change (Lacoste et al., 2015).

4.2. Map prediction according to soil type

SOC_s of the new national digital map (mean = 71.1 MgC·ha⁻¹) with variation coefficient of 29% is different compared to the values given by Grinand et al. (2009) which used 279 soil profiles (sampled before 1973). The range was from 1.2 to 198.8 MgC·ha⁻¹ with estimated mean of 50.1 MgC·ha⁻¹. This difference can be explained by the difference in SOC_s database which we used for modelling (Table 1). In this study, we used 835 plot data from 2010 to 2015 surveys. Moreover, the minimum




Fig. 5. Scatterplot of SOC_s predictions proposed by Grinand et al. (2009) and by our model for random points ($n = 1365$) in the county of Didy.

value of Grinand et al. (2009) corresponds to lithic raw mineral soils (FAO, 2014: Regosols/leptosols/arenosols), in our case, the minimum value comes from the SOC_s given on ferruginous soil (FAO, 2014: Ferric Luvisols) with a minimum of $28.3 \text{ MgC} \cdot \text{ha}^{-1}$ (Mean = $57.05 \text{ MgC} \cdot \text{ha}^{-1}$). Razafimahatratra (2011) proved that lithosols, along with arenosol are both chemically exhausted soil types that are highly sensitive to erosion in perhumid tropics and with a lower SOC_s content than that of Ferrallitic soils (FAO, 2014: Ferralsols; mean = $80.96 \text{ MgC} \cdot \text{ha}^{-1}$, Table 3). The maximum value of our SOC_s prediction comes from the values of andosols

(max = $197.6 \text{ MgC} \cdot \text{ha}^{-1}$; mean = $116.4 \text{ MgC} \cdot \text{ha}^{-1}$), similarly to Grinand et al. (2009); these values correspond to moderately developed soils (FAO, 2014: Cambisols). Andosols have a tendency to bind organic matter and therefore often contain much more organic materials than other soils under similar conditions (FAO, 2014).

Considering determination according to soil type, the mean SOC_s map predicted by our model was higher than those previously determined (Grinand et al., 2009), except for podzolic soils and podzols (FAO, 2014: Podzols) $66.6 \text{ MgC} \cdot \text{ha}^{-1}$ and $61 \text{ MgC} \cdot \text{ha}^{-1}$. Therefore, our national model, did not predict SOC_s values on lithic raw mineral soils because of lack of SOC_s values on our updated database.

4.3. Limitations

The new national map produced with our method improved the spatial resolution, from 1 km for Grinand et al. (2009) (Fig. 7) to 30 m in the new digital map (Fig. 6). We showed also that accuracy was better, representing subtle SOC_s change within the landscape. Although the spatial variables have a wide range of ground resolution, the downscaling in the finest resolution considers the gradients of the original resolutions such as climate data (Cavazzi et al., 2013) and topographic data (Grinand et al., 2017). For a model of SOC_s with R^2 of 0.65, Vagen and Winowiecki (2013) showed that a SOC_s map at 30 m resolution can assist with soil and landscape management. In addition, by using randomForest, Hengl et al. (2015) mentioned the better performance of an improved spatial resolution map.

According to the validation sample (Fig. 2), the main limit of the prediction was observed when predicting high SOC_s values, thus affecting Ferralsols, Andosols, and hydromorphic soils (Fluvisols/histosols). However, according Fig. 8, pixels with highest values are scarce.

By considering the representativeness of the sampling points across the country, the range of collected data may affect the applicability of the model in different areas (Ryan et al., 2000). The prediction of SOC_s should be improved by a good sampling design which follows a good representation of the spatial variables dataset (Ließ et al., 2016).

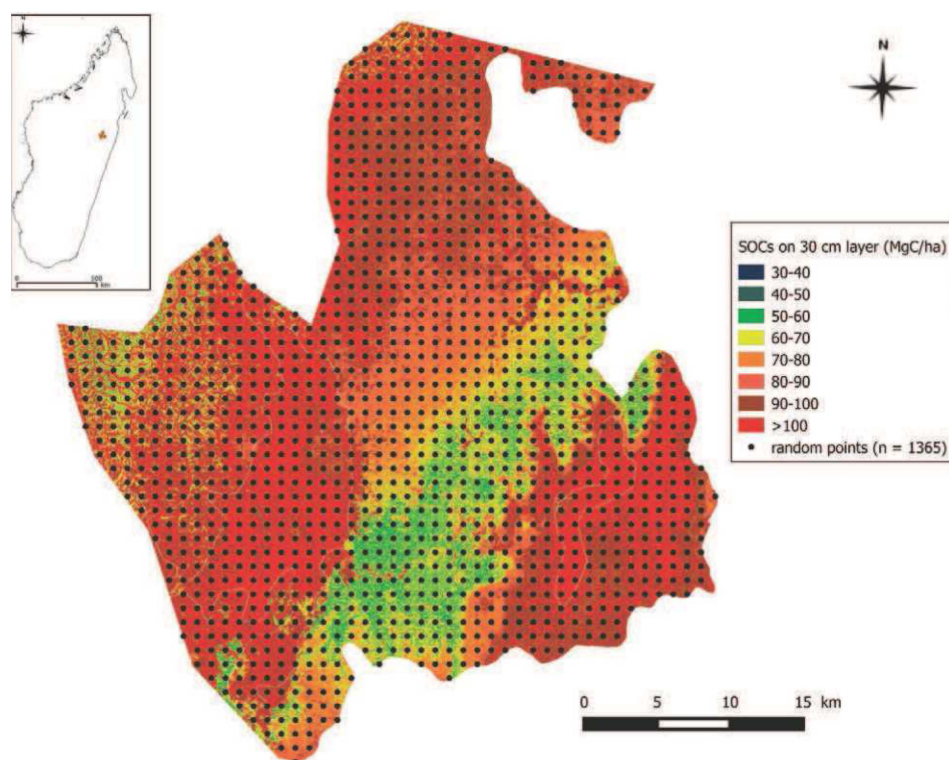


Fig. 6. SOC_s map for the first 30 cm layer in the county of Didy according to the predictive model's national map.

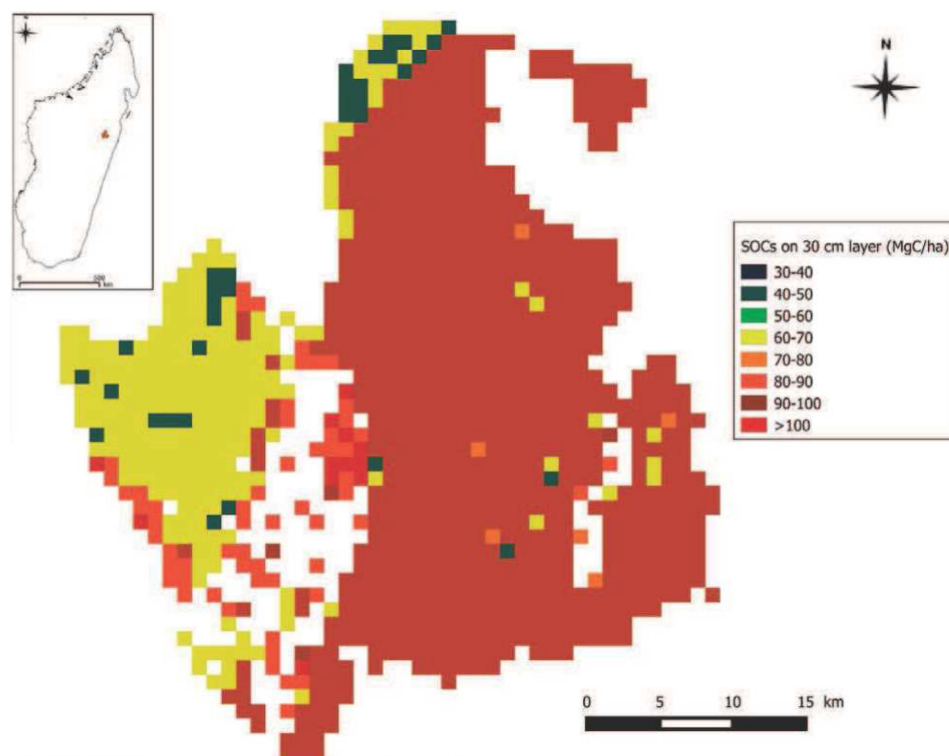


Fig. 7. SOC_s map for the first 30 cm layer in the county of Didy according to the national map by Grinand et al. (2009).

Another limitation could arise from difference in survey date. Most of the data used in our study were collected within the last five years and land use changes could have occurred between our study period and the older period considered by the Grinand et al. (2009) study. Also, the production of annual reference satellite cover of Madagascar at higher resolution, using for instance SENTINEL-2 images at 10 m resolution freely available from 2015, could be recommended to update the predictor variables related to satellite derived reflectance indexes.

Finally, the presence of unpredicted pixels challenged the research to work in other areas by collecting as much detail as possible about

the physical and environmental characteristics, in particular soil type according to the Word Reference Base of soil resources (FAO, 2014) and land use of sampling points.

5. Conclusion

This study improved the scale and accuracy of the national map of SOC_s of Madagascar for the 30 cm surface soil layer in comparison with the one previously produced in 2009. The main innovation is the use of an updated database of recent soil surveys and newly available satellite data standardized at national scale. It could help to more precisely assess soil responses to environmental changes, including the assessment of C storage potential that is important for mitigating climate change, spatial distribution of SOC_s and the most relevant factors explaining SOC_s distribution. This map could be easily update as new soil data are been collected on the field and new spatial dataset are made available. Also, it can be served as basis for soil organic change detection at local and national extent. More research is needed in Madagascar to assess the land use and land cover change effect on soil organic carbon from landscape to national scale.

Acknowledgements

This study was mainly supported by the French Institute of Research for Development (IRD) through the financing of the PEERS-CarSoM project (Programme d'Enseignement pour la Recherche au Sud-Carbone des Sols de Madagascar, PEERS-CarSoM), by the Inter-institutional Agency of Research for the development (AIRD) and the French Ministry of foreign affairs (MAEDI). We are grateful to all of the main partners of Laboratory of Radiolotopes which supplied data in VALSOL-Madagascar: (i) IRD-UMR Eco&Sols (<http://www.umn-ecosols.fr>) (ii) Africa Soil Information Service (AfSIS) project funded by the Bill and Melinda Gates Foundation Grant Number 51353 (<http://africasoils.net/>) (iii) p4GES project Carbon work package funded by NERC-ESPA programme/project number NE/K008692/1 (www.p4ges.org/) (iv) FSP PARRUR: Solidarity and Priority Fund-Partnership and Research in the Rural Sector




Fig. 8. Frequency of pixel according SOC_s map.

(<http://www.fsp-parrur.irenala.edu.mg/>) (v) IFS: International Foundation for Science through a grant to RESEARCH GRANT AGREEMENT NO. D/5280-1 (<http://www.ifs.se/>) (vi) Holistic Program of Forest Conservation (PHCF) (<http://phcf.actioncarbome.org/>) (vii) PERR-FH: Ecoregional REDD + project, Eastern humid Forest funded by the World Bank Institute (<http://www.perr-fh-mada.net/>) (viii) BIOVA project: Recycling Plant & Animal biomass in agricultural funded by European union and African Union (<http://www.biova-project.org/>). This work is also associated to the “Soil-carbon-Africa” network (<http://reseau-carbone-sol-afrique.org/>).

Appendix A. Supplementary data

Supplementary data to this article can be found online at <http://dx.doi.org/10.1016/j.geodrs.2016.12.002>.

References

- Batjes, N.H., 1996. Total carbon and nitrogen in the soils of the world. *Eur. J. Soil Sci.* 47, 151–163.
- Beaudou, A., Le Martret, H., 2004. MIRURAM/VALSOL: Un système d'information et une base de données pour représenter les sols tropicaux et leurs environnements. *Étude et gestion des sols* 11, 271–284.
- Bernoux, M., de Carvalho, S.M., Volkoff, B., Cerri, C.C., 2002. Brazil's soil carbon stocks. *Soil Sci. Soc. Am.* 66, 888–896.
- Bolin, B., Sukumar, R., Ciais, P., Crater, W., Jarvis, P., Khesghi, H., Nobre, C., Semenov, S., Steffen, W., 2001. Global perspective. In: Watson, R.T., Noble, I.R., Bolin, B., Ravindranath, N.H., Verardo, D.J., Dokken, D.J. (Eds.), IPCC Special Report on Land Use, Land-use Change and Forestry. Cambridge University Press, Cambridge, pp. 23–51.
- Breiman, L., 2001. Random forests. *Mach. Learn.* 45, 5–32.
- Cavazzi, S., Corstanje, R., Mayr, T., Hannam, J., Fealy, R., 2013. Are fine resolution digital elevation models always the best choice in digital soil mapping? *Geoderma*. <http://dx.doi.org/10.1016/j.geoderma.2012.11.020>.
- Chapuis-Lardy, L., Brossard, M., Lopes-Assad, M.L., Lau-Ent, J.Y., 2002. Carbon and phosphorus stocks of clayey Ferralsols in Cerrado native and agroecosystems, Brazil. *Agric. Ecosyst. Environ.* 92, 147–158.
- CNES, 2014. Distributions Astrium Services/SPOT Image SA/France. MNT.tif.
- CPCS, 1967. Classification des sols. Travaux Commission de Pédologie et de Cartographie des Sols. Rapport Multiple, Grignon, p. 96.
- Davidson, E.A., Janssens, I.A., 2006. Temperature sensitivity of soil carbon decomposition and feedbacks to climate change. *Nature* 440, 165–173.
- Delenne, M., Pelletier, F., 1980. Carte des conditions géographiques de la mise en valeur agricole de Madagascar: thème 1: potentiel des unités physiques à 1/1.000.000. ORSTOM, Office de la recherche scientifique et technique outre-mer, Bondy, France (3 feuilles).
- Delmas, M., Saby, N., Arrouays, D., Dupas, R., Lemerrier, B., Pellerin, S., Gascuel-Oudoux, C., 2015. Explaining and mapping total phosphorus content in French topsoil. *Soil Use Manag.* 31, 259–269.
- Duchaufour, P., 1998. Reflexions sur les classifications des sols. *Étude et gestion des sols* 5, 201–205.
- Fang, J., Guo, Z., Hu, H., Kato, T., Muraoka, H., Son, Y., 2014. Forest biomass carbon sinks in East Asia, with special reference to the relative contributions of forest expansion and forest growth. *Glob. Chang. Biol.* 20, 2019–2030.
- FAO, 2014. World Reference Base for Soil Resources. *World Soil Resource Report 106* (Rome, 203p).
- Gao, B., 1996. NDWI—a normalized difference water index for remote sensing of vegetation liquid water from space. *Remote Sens. Environ.* 58, 257–266.
- Genuer, R., Poggi, J.M., Tuleau-Malot, C., 2014. VSURF: un package R pour la sélection de variables à l'aide de forêts aléatoires. 46èmes Journées de Statistique, Rennes, France, pp. 1–23.
- Grace, J., San-José, J., Meir, P., Miranda, H.S., Montes, R.A., 2006. Productivity and carbon fluxes of tropical savannas. *J. Biogeogr.* 33, 387–400.
- Grimm, R., Behrens, T., Marker, M., Elsenbeer, H., 2008. Soil organic carbon concentrations and stocks on Barro Colorado Island—digital soil mapping using random forests analysis. *Geoderma*. <http://dx.doi.org/10.1016/j.geoderma.2008.05.008>.
- Grinand, C., Rajaonarivo, A., Bernoux, M., Pajot, V., Brossard, M., Razafimbelo, T., Albrecht, A., Le Martret, H., 2009. Estimation des stocks de Carbone dans les sols de Madagascar. *Étude et Gestion des Sols* 16, 23–33.
- Grinand, C., Le Maire, G., Vieilledent, G., Razakamanarivo, H., Razafimbelo, T., 2017. Estimating temporal changes in soil carbon stocks at ecoregional scale in Madagascar using remote-sensing. *Int. J. Appl. Earth Obs. Geoinf.* 54, 1–14.
- Grunwald, S., 2009. Multi-criteria characterization of recent digital soil mapping and modeling approaches. *Geoderma* 152, 195–207.
- Hansen, M., Potapov, P., Moore, R., Hancher, M., Turubanova, S., Tyukavina, A., Thau, D., Stehman, S., Goet, S., Loveland, T., Kommareddy, A., Egorov, A., Chini, L., Justice, C., Townshend, J., 2013. High-resolution global maps of 21st-century forest cover change. *Science* 342, 850–853.
- Harper, G., Steininger, M.K., Tucker, C.J., Juhn, D., Hawkins, F., 2007. Fifty years of deforestation and forest fragmentation in Madagascar. *Environ. Conserv.* 34. <http://dx.doi.org/10.1017/S0376892907004262>.
- Hastie, T., Tibshirani, R., Friedman, J., 2009. The Elements of Statistical Learning. Data Mining, Inference, and Prediction. second ed. Springer Series in Statistics pp. 1–263.
- Hempel, J.W., Hammer, R.D., Moore, A.C., Bell, J.C., Thompson, J.A., Golden, M.L., 2005. Challenge to digital soil mapping. In: Hartemink, A.E., McBratney, A., Mendonça-Santos, M.D.L. (Eds.), *Digital Soil Mapping With Limit Data*. Springer, pp. 81–90.
- Hengl, T., Heuvelink, G.B., Kempen, B., Leenaars, J.G., Walsh, M.G., Sheperd, K.D., Sila, A., MacMillan, R.A., Mendes, D.J., Tamene, L., Tondoh, J., 2015. Mapping soil properties of Africa at 250 m resolution: random forests significantly improve current predictions. *PLoS One* 10. <http://dx.doi.org/10.1371/journal.pone.0125814>.
- Hijmans, R., Cameron, J., Parra, P., Jones, P.G., Jarvis, A., 2005. Very high resolution interpolated climate surfaces for global land areas. *Int. J. Climatol.* 25, 1965–1978.
- Kim, J., Grunwald, S., Rivero, R.G., Robbins, R., 2012. Multi-scale modeling of soil series using remote sensing in a wetland ecosystem. *Soil Sci. Soc. Am.* 7. <http://dx.doi.org/10.2136/sssaj2012.0043>.
- Kutsch, W.L., Bahn, M., Heinemeyer, A., 2009. Soil carbon relations: an overview. In: Kutsch, W.L., Bahn, M., Heinemeyer, A. (Eds.), *Soil Carbon Dynamics: an Integrated Methodology*. Cambridge University Press, Cambridge, pp. 1–15.
- Lacoste, M., Viaud, V., Michot, D., Walter, C., 2015. Landscape-scale modelling of erosion processes and soil carbon dynamics under land-use and climate change in agroecosystems. *Eur. J. Soil Sci.* 780, 1–12.
- Lagacherie, P., 2007. Digital soil mapping: a state of the art. In: Hartemink, A.E., McBratney, A., Mendonça-Santos, M.D.L. (Eds.), *Digital Soil Mapping with Limit Data*. Springer, pp. 3–14.
- Lagacherie, P., McBratney, A.B., 2007. Spatial soil information systems and spatial soil inference systems: perspectives for digital soil mapping. In: Lagacherie, P., McBratney, A.B., Voltz, M. (Eds.), *Digital Soil Mapping: an Introductory Perspective*. Dev. Soil Sci. 31. Elsevier, Amsterdam, pp. 1217–1218.
- Legros, J.P., 2006. Mapping of the Soil. Science Publishers, Enfield, p. 411.
- Leprun, J.C., Razafinjara, L., Andrianahina, R., Feller, C., Bourgeat, F., Brossard, M., Riquier, J., Roederer, P., Ségalen, P., Serpantié, G., Sourdat, M., Vieillefont, J., Vizio, F., 2010. Pédologie. In: Feller, C., Sandron, F. (Eds.), *Parcours de recherche à Madagascar: l'IRD-ORSTOM et ses partenaires*. Marseille, pp. 247–293.
- Lieff, M., Schmidt, J., Glaser, B., 2016. Improving the spatial prediction of soil organic carbon stocks in a complex tropical mountain landscape by methodological specifications in machine learning approaches. *PLoS One* 11. <http://dx.doi.org/10.1371/journal.pone.0153673>.
- Martin, D., Lal, T., Sachdev, C.B., Sharma, J.P., 2010. Soil organic carbon storage changes with climate change, landform and land use conditions in Garhwal hills of the Indian Himalayan mountains. *Agric. Ecosyst. Environ.* 138, 64–73.
- Martin, M.P., Wattenbach, M., Smith, P., Meersmans, J., Jolivet, C., Boulonne, L., Arrouays, D., 2011. Spatial distribution of soil organic carbon stocks in France. *Biogeosciences*. <http://dx.doi.org/10.5194/bg-8-1053-2011>.
- Matsuura, S., Sasaki, H., Kohyama, K., 2012. Organic carbon stocks in grassland soils and their spatial distribution in Japan. *Japan. Soc. Grassl. Sci.* <http://dx.doi.org/10.111/j.1744-697X.2012.00245.x>.
- McBratney, A.B., Mendonça Santos, M.L., Minasny, B., 2003. On digital soil mapping. *Geoderma* 117, 3–52.
- McKinley, D.C., Ryan, M.G., Birdsey, R.A., Giardina, C.P., Harmon, M.E., Heath, L.S., Houghton, R.A., Jackson, R.B., Morrison, J.F., Murray, B.C., Pataki, D.E., Skog, K.E., et al., 2011. A synthesis of current knowledge on forests and carbon storage in the United States. *Ecol. Appl.* 21, 1902–1924.
- Millennium Ecosystem Assessment, 2005. *Ecosystems and Human Well-being: Synthesis*. Island Press, Washington, DC.
- Minasny, B., McBratney, A., Malone, B., Wheeler, I., 2013. Digital mapping of soil carbon. *Adv. Agron.* 118, 1–47.
- Moat, J., Smith, P., 2007. *Atlas of the Vegetation of Madagascar*. Kew publishing, Royal Botanic Gardens, p. 124.
- Mustafa, A., Man, S., Sahoo, R., Nayan, A., Manok, K., Sarangi, A., Mishra, A., 2010. Mapping of Degraded Lands from Multiscale Remotely Sensed Data Using Decision Tree Based Classification (DTC). *Indian Agricultural Research Institute*, pp. 33–55.
- Nussbaum, M., Papritz, A., Baltensweiler, A., Walthert, L., 2014. Estimating soil organic carbon stocks of Swiss forest soils by robust external-drift kriging. *Geosci. Model Dev.* 7, 1197–1210.
- Pan, Y., Birdsey, R.A., Fang, J., Houghton, R., Kauppi, P.E., Kurz, W.A., Phillips, O.L., Shvidenko, A., Lewis, S.L., Canadell, J.G., Ciais, P., Jackson, R.B., Pacala, S.W., McGuire, A.D., Piao, S., Rautiainen, A., Sitch, S., Hayes, D., 2011. A large and persistent carbon sink in the world's forests. *Science* 333, 988–993.
- Penman, J., Gyatarsky, M., Hiraishi, T., Kruger, D., Pipatti, R., Buendia, L., Miwa, K., Ngara, T., Tanabe, K., Wagner, F., 2003. In: Intergovernmental Panel on Climate Change Institute (IPCC) (Ed.), *Good Practice Guidance for Land Use, Land-use Change and Forestry*. Institute for Global Environmental Strategies (IGES), Japan (pp. 1.1–1R.5).
- QGIS, 2014. QGIS User Guide, Version 2.2 (QGIS project.303p).
- Razafimahatratra, H., 2011. Sols malgaches et spectroscopie dans le moyen infrarouge: classification, caractérisation et sensibilité au climat. PhD thesis. ESSA University of Antananarivo Madagascar, p. 189.
- Razafimbelo, T., Albrecht, A., Oliver, R., Chevallier, T., Chapuis-Lardy, L., Feller, C., 2008. Aggregate associated-C and physical protection in a tropical clayey soil under Malagasy conventional and no-tillage systems. *Soil Tillage Res.* 98, 140–149.
- Razakamanarivo, H., Grinand, C., Razafindrakoto, M.A., Bernoux, M., Albrecht, A., 2011. Mapping organic carbon stocks in eucalyptus plantations of the central highlands of Madagascar: a multiple regression approach. *Geoderma* 162, 335–346.
- Reeves III, J., 2010. Near- versus mid-infrared diffuse reflectance spectroscopy for soil analysis emphasizing carbon and laboratory versus on-site analysis: where are we and what needs to be done? *Geoderma* 158. <http://dx.doi.org/10.1016/j.geoderma.2009.04.005>.

- Rossel, V., Brus, D.J., Lobsey, C., Shi, Z., McLachlan, G., 2016. Baseline estimates of soil organic carbon by proximal sensing: comparing design-based, model-assisted and model-based inference. *Geoderma* 265, 152–163.
- Rouse, J., Hass, R., Schell, J., Deering, D., 1974. Monitoring vegetation systems in the Great Plains with ERTS. In: Franden, S., Marcanti, E., Becker, M. (Eds.), *Third ERTS-1 Symposium* Washington D.C, pp. 309–317.
- Ryan, P., McKenzie, N., O'Connell, D., Loughhead, A., Leppert, P., Jacquier, D., Ashton, L., 2000. Integrating forest soils information across scales: spatial prediction of soil properties under Australian forests. *For. Ecol. Manag.* 138. [http://dx.doi.org/10.1016/S0378-1127\(00\)00393-5](http://dx.doi.org/10.1016/S0378-1127(00)00393-5).
- Sreenivas, K., Sujatha, G., Sudhir, K., Vamsi, D., Fyze, M., Ravisankar, T., Dadhwal, V., 2014. Spatial assessment of soil organic carbon density through random forests based imputation. *J. Indian Soc. Remote Sens.* 42, 577–587.
- Styger, E., Fernandes, E.C.M., Rakotondramasy, H.M., Rajaobelirina, E., 2009. Degrading uplands in the rainforest region of Madagascar: fallow biomass, nutrient stocks, and soil nutrient availability. *Agrofor. Syst.* 77, 107–122.
- Suuster, E., Ritz, C., Roostalu, H., Kölli, R., Astover, A., 2012. Modelling soil organic carbon concentration of mineral soils in arable land using legacy soil data. *Eur. J. Soil Sci.* 63, 351–359.
- Vagen, T.G., Winowiecki, L.A., 2013. Mapping of soil organic carbon stocks for spatially explicit assessments of climate change mitigation potential. *Environ. Res. Lett.* 8, 1–9.
- Vagen, T.G., Andrianorofanomezana, M.A.A., Andrianorofanomezana, S., 2006. Deforestation and cultivation effects on characteristics of oxisols in the highlands of Madagascar. *Geoderma* 131. <http://dx.doi.org/10.1016/j.geoderma.2005.03.026>.
- Vagen, T.G., Winowiecki, L.A., Tondoh, J.E., Desta, L.T., Gumbricht, T., 2016. Mapping of soil properties and land degradation in Africa using MODIS reflectance. *Geoderma* 263, 216–225.
- Walkley, A., Black, J., 1934. An examination of the Degtjareff method for determining soil organic matter and a proposed modification of the chromic titration method. *Soil Sci.* 37, 29–38.
- Wang, Y., Li, Y., Ye, Y., Chu, X., Wang, X., 2010. Profile storage of organic/inorganic carbon in soil: from forest to desert. *Sci. Total Environ.* 408, 1925–1931.
- Wang, G., Zhou, Y., Xu, X., Ruan, H., Wang, J., 2013. Temperature sensitivity of soil organic carbon mineralization along an elevation gradient in the Wuyi Mountains, China. *PLoS One*. <http://dx.doi.org/10.1371/journal.pone.0053914>.
- Wei, C., Rowe, G., Escobar-Briones, E., Boetius, A., Soltwedel, T., Caley, M., 2010. Global patterns and predictions of seafloor biomass using random forests. *PLoS One* 5. <http://dx.doi.org/10.1371/journal.pone.0015323>.
- Were, K., Ram, B., Bjarne, O., 2016. Spatially distributed modelling and mapping of soil organic carbon and total nitrogen stocks in the Eastern Mau Forest Reserve, Kenya. *J. Geogr. Sci.* <http://dx.doi.org/10.1007/s11442-016-1257-4>.
- White, R., Murray, S., Rohweder, M., 2000. Carbon storage. In: Kalai, K.K. (Ed.), *Pilot Analysis of Global Ecosystems: Grassland Ecosystems*. World Resources Institute, Washington, pp. 49–53.
- Yigini, Y., Panagos, P., 2014. Reference area method for mapping soil organic carbon content at regional scale. *Procedia Earth Planet Sci.* 10, 330–338.